

Univerzita Karlova
Přírodovědecká fakulta

Obor kartografie a geoinformatiky



Bc. Michal Launer

Určení druhové skladby lesa z družicových dat
Forest species determination from satellite data

Diplomová práce

Vedoucí diplomové práce: Doc. Ing. Jan Kolář, CSc.

Praha, 2017

Prohlášení:

Prohlašuji, že jsem závěrečnou práci zpracoval/a samostatně a že jsem uvedl/a všechny použité informační zdroje a literaturu. Tato práce ani její podstatná část nebyla předložena k získání jiného nebo stejného akademického titulu.

V Praze, 28.07.2017

Podpis

POĎAKOVANIE

Ďakujem Doc. Ing. Jánovi Kolářovi, CSc. za jeho odborné vedenie práce, za jeho cenné rady a pripomienky, ktoré mi poskytoval počas celej doby práce na diplomovej práci. Ďakujem tiež RNDr. Jakubovi Lsákovi, Ph.D. za jeho cenné rady ohľadom používania softvéru ArcGIS. Ďakujem LD Osvětmany a LS Buchlovice za poskytnutie dát, ktoré mohli byť použité ako referenčná vrstva.

Určení druhové skladby lesa z družicových dat

Abstrakt

Skúmanie druhového zloženia lesov z družicových snímok sa neustále vyvíja. Nové spôsoby skúmania lesov z družíc uľahčujú lesníkom si udržiavať presnejší a aktuálny prehľad o stave lesov.

V tejto práci výskum bol robený na lesoch v katastrálnych územiach Osvětimany a Buchlovice v pohorí Chřibý v České republice. V práci boli využité dáta zo satelitu Landsat-8 z troch ročných období a metóda Maximum Likelihood Classification. Ako referenčné dáta boli použité lesnícke porastové mapy.

Metóda práce spočívala v klasifikácii 6 snímok pomocou trénovacích množín metódou Maximum Likelihood Classification. Následne boli vybraté pixle, ktoré boli po klasifikácii aspoň 4-krát zo 6 zaradené do tej istej triedy.

Na základe týchto pixlov boli vypočítané umelé trénovacie množiny pre každú zo 6 snímok, pomocou ktorých bola urobené ďalšia klasifikácia s očakávaním lepších výsledkov.

Správnosť jednotlivých klasifikácií snímok bola overená pomocou chybovej matice na porastových mapách.

Kľúčové slová: dálkový průzkum, lesní porost, druhy lesa, lesnická hospodářská mapa

Forest species determination from satellite data

Abstract

Examining the species composition of forests from satellite imagery is constantly evolving. The new ways of exploring forests from the satellites make it easier for foresters to maintain a more accurate and up-to-date overview of the state of forests.

In this work, the research was made on the forests in the cadastral territories of Osvětimany and Buchlovice in the Chřibý Mountains in the Czech Republic. In this work, data from the Landsat-8 satellite from three seasons and the Maximum Likelihood Classification method were used. The reference maps were used as reference data.

The method of work consists in the fact that 6 frames were classified with the help of training sets using Maximum Likelihood Classification. Subsequently, the pixels which were at least 4 times out of 6 ranked in the same class after the classification were selected.

Based on these pixels, artificial training sets were calculated for each of the 6 frames, and they were used for another classification with the expectation of better results.

The accuracy of the individual classification frames was verified by an error matrix on the crop maps.

Keywords: remote sensing, forest canopy, forest tree types, forestry map

Obsah

1	Úvod	10
1.1	Využitie diaľkového prieskumu zeme v lesníctve	10
1.2	Využitie druhej skladby lesa	11
1.3	Vymedzenie oblasti výskumnej témy diplomovej práce	12
1.4	Základný popis výskumných otázok, ktoré pripadajú v úvahu pre spracovanie v diplomovej práci	12
2	Literárne rešerše vzťahujúce sa k danej úlohe.....	13
3	Prehľad potrebných dát a ich zdrojov	16
4	Návrh metódy	17
5	Návrh postupu práce.....	19
5.1	Výber vhodného softvéru na spracovanie dát	19
5.2	Úprava mapových podkladov	19
5.3	Georeferencovanie	19
5.4	Výber vhodných snímok	20
5.5	Atmosférická korekcia	20
5.6	Topografická korekcia	20
5.7	Odfiltrovanie oblakov, ich tieňov a oparu.....	20
5.8	Rozoznanie pixlov pokrytých vegetáciou a holou zemou	21
5.9	Výber a vyhotovenie diskriminačnej analýzy a kanálov	21
5.10	Výber klasifikačných tried, tréningových a testovacích vzoriek pixlov	22
5.11	Maximum Likelihood Classification	22
5.12	Chybová matica	23
6	Priebeh práce a výpočty	25
6.1	Výber vhodného softvéru na spracovanie dát	25
6.2	Úprava mapových podkladov	25
6.3	Georeferencovanie	25
6.4	Výber vhodných snímok	26
6.5	Atmosférická korekcia	26
6.6	Topografická korekcia	26
6.7	Odfiltrovanie oblakov, tieňov a oparu	26
6.8	Rozoznanie pixlov pokrytých vegetáciou a holou zemou	27
6.9	Výber a vyhotovenie diskriminačnej analýzy a kanálov	27
6.10	Výber klasifikačných tried, tréningových a testovacích vzoriek pixlov	28
6.11	Priebeh klasifikácie.....	29

6.12	Porovnávanie výsledkov	30
6.13	Vytvorenie umelej trénovacej množiny pixlov	30
6.14	Porovnanie výsledkov pomocou chybovej matice	31
7	Diskusia.....	32
7.1	Porovnanie výsledkov z pohľadu druhov množín pixlov a klasifikačných tried 32	
7.2	Porovnanie výsledkov v rámci snímok.....	32
7.3	Návrhy na zlepšenie výsledkov	33
8	Záver.....	35
9	Použité zdroje a literatúra.....	36
10	Prílohy	i
10.1	Klasifikácia lesov podľa trénovacích množín k.ú. Osvětman a Buchlovíc ...i	
10.2	Klasifikácia lesov podľa trénovacích množín k.ú. Osvětman a Buchlovíc (2) ii	
10.3	Chybové matice klasifikácie lesov podľa trénovacích množín k.ú. Osvětman a Buchlovíc	iii
10.4	Klasifikácia lesov na základe 6 snímok podľa trénovacích množín k.ú. Osvětman a Buchlovíc	iv
10.5	Klasifikácia lesov podľa umelých trénovacích množín k.ú. Osvětman a Buchlovíc	v
10.6	Klasifikácia lesov podľa umelých trénovacích množín k.ú. Osvětman a Buchlovíc (2).....	vi
10.7	Chybové matice klasifikácie lesov podľa umelých trénovacích množín k.ú. Osvětman a Buchlovíc	vii
10.8	Klasifikácia lesov podľa testovacích množín k.ú. Osvětman a Buchlovíc	viii
10.9	Klasifikácia lesov podľa testovacích množín k.ú. Osvětman a Buchlovíc (2) ix	
10.10	Chybové matice klasifikácie lesov podľa testovacích množín k.ú. Osvětman a Buchlovíc	x

Zoznam skratiek

ARVI	– Atmospherically resistant vegetation index
B	– Blue (band) <i>modrý kanál</i>
C	– Coastal (band) <i>pobrežný kanál</i>
ČUZK	– Český úrad zeměměřický a katastrální (office)
DCM	– Digital canopy model (model) <i>digitálny model súvislej vrstvy korún stromov</i>
DPZ	– Remote Sensing (science) <i>Diaľkový prieskum zeme</i>
DTM	– Digital terrain model (model) <i>digitálny model terénu</i>
EVI	– Enhance vegetation index
G	– Green (band) <i>zelený kanál</i>
HMS	– Multispectral images (data) <i>multispektrálne snímky</i>
L-8	– Landsat-8 (satellite) <i>družica</i>
LDA	– Linear Discriminant Analysis (method) <i>Lineárne diskriminačné analýzy</i>
MD	– Mahalanobis distance (method) <i>Mahalanobisová vzdialenosť</i>
MDA	– Mean decrease in accuracy (method) <i>metóda</i>
MDFC	– Mean discriminant function coefficients (method) <i>metóda</i>
MDG	– Mean decrease in Gini (method) <i>Stredná hodnota v Giniho koeficientu</i>
NDVI	– Normalized difference vegetation index <i>Normalizovaný diferenčný vegetačný index</i>
NIR1	– Near Infrared (band) <i>blízke infračervené pásmo</i>
NLC	– <i>Národné lesnícke centrum vo Zvolene Slovenskej republiky</i> (office) <i>ústav</i>
NN	– Neural network (method) <i>neurónové siete</i>
OA	– Overall accuracy <i>celková presnosť</i>
OBIA	– Object-based image analysis (method) <i>objektová obrazová analýza</i>
OKC	– Overall kappa coefficient <i>celkový kappa koeficient</i>
PCA	– Principal Component Analysis (method) <i>metóda hlavných komponent</i>
PDA	– Penalized discriminant analysis (method of linear combinations) <i>metóda lineárnych kombinácií</i>
R	– Red (band) <i>červené pásmo</i>
RE	– Red-Edge (band) <i>krajné červené pásmo</i>

RF	– Random Forest (method) <i>metóda</i>
S-2	– Sentinel-2 (satellite) <i>družica</i>
SAM	– Spectral angle mapper (method) <i>metóda</i>
SID	– Spectral information divergence (method) <i>metóda</i>
SpecTex	– HMS spectral-spatial texture image (data) <i>spektrálno-priestorový texturálny obraz</i>
S-JTSK	– Systém jednotné trigonometrické sítě katastrální (coordination system) <i>súradnicový systém</i>
SVM	– Support vector machine (method)
QB	– QuickBird (satellite) <i>družica</i>
UHUL	– Ústav pre hospodársku úpravu lesov Brandýs nad Labem (office) <i>ústav</i>
USGS	– U.S. Geological Survey (office) <i>ústav</i>
VARI	– Visible atmospherically resistant index <i>viditeľný atmosférický rezistentný index</i>
VI _s	– Vegetation index <i>vegetačné indexy</i>
VRE	– Vegetation Red Edge (band) <i>vegetačné krajné červené pásmo</i>
VW-2	– World View-2 (satellite) <i>družica</i>
WGS84	– World Geodetic System 1984 (coordination system) <i>súradnicový systém</i>
ZM 1:10 000	– Základná mapa Českej republiky 1:10 000 (map)

Vysvetlivky zdrojov

(1) – odkaz na zdroj literatúry

[a] – odkaz na zdroj dát

1 Úvod

1.1 Využitie diaľkového prieskumu zeme v lesníctve

V lesníctve sa používajú metódy diaľkového prieskumu zeme (ďalej DPZ) pre rýchle získanie informácií o stave lesa, bez potreby detailného plošného terénneho prieskumu. Metódy DPZ sa v lesníctve využívajú na skúmanie druhového zloženia, vekového zloženia a zdravotného stavu lesov. Taktiež sa využívajú na monitorovanie stavu lesov po rôznych prírodných katastrofách ako sú napr. požiare a veterné smršte.

Rozvoju metód na celosvetovej úrovni prispievajú okrem pribúdajúcich algoritmov aj spôsoby získavania dát. V posledných rokoch sa k leteckému snímkovaniu, k radarovým a multispektrálnym družiciam pridali aj hyperspektrálne družice a letecké laserové skenovanie. Tiež pribudol aj nový druh nosičov pre senzory. K lietadlám a družiciam sa pridali drony.

Významný vplyv na neustále zvyšujúcu presnosť klasifikácie má aj vývoj stále výkonnejších senzorov, vďaka ktorým sa vytvárajú dáta so stále väčším priestorovým rozlíšením.

V súčasnosti z voľne dostupných snímok sú na skúmanie vegetácie najvhodnejšie snímky z optických multispektrálnych družíc Landsat-8 a Sentinel-2. Landsat-8 sníma v 11 pásmach. Panchromatické pásmo má priestorové rozlíšenie 15 m a všetky ostatné pásma majú priestorové rozlíšenie 30 m. Družica Sentinel-2 sníma v 12 pásmach a snímky majú v jednotlivých pásmach priestorové rozlíšenie 10 až 60 m.

Z komerčných družíc najväčšie priestorové rozlíšenie majú WorldView-2, Quick-Bird, Ikonos, Spot. WorldView-2 má priestorové rozlíšenie panchromatického pásma 0,46 m a multispektrálnych pásiem 1,84 m. Quick-Bird má priestorové rozlíšenie panchromatického pásma 0,61 m. Priestorové rozlíšenie multispektrálnych pásiem pri snímkach veľkosti 450 x 450 km je 2,44 m a pri snímkach veľkosti 300 x 300 km 1,63 m. Ďalšími komerčnými družicami sú Ikonos s priestorovým rozlíšením snímok 1 - 4 m a Spot s rozlíšením 1,5 - 6 m.

Od zberu dát v rôznych podobách s rôznou rozlišovacou schopnosťou sa následne odvíja predspracovanie dát a následne vývoj metód. V prípade optických družicových dát si autor volí klasifikačné príznaky a to spektrálne, priestorové, texturálne a časové. Volí si medzi pixelovou a objektovou klasifikáciou. Taktiež je potrebné si zvoliť klasifikačný algoritmus riadenej klasifikácie, neriadenej klasifikácie alebo algoritmus strojového učenia napr. neural network (ďalej NN), Random Forest (ďalej RF), atď.

V súčasnosti sa vo svete používajú najčastejšie metódy napr. Random Forest, Linear Discriminant Analysis (ďalej LDA) a Valleyfollowing Approach.

V Českej republike v Ústave pre hospodársku úpravu lesov (ďalej UHUL) a na Slovensku v Národnom lesníckom centre (ďalej NLC) sa v DPZ v lesníctve využívajú predovšetkým voľne dostupné dáta z optických družíc Landsat a Sentinel, snímky

z leteckého snímkovania a snímky z dronov. Tiež sa vo veľkej miere využívajú snímky z družíc Terra a Aqua, ktoré sú vybavené spektorrádiometrom, ktorý sníma v 36 kanáloch s rozlišovacou schopnosťou 250 m až 1 km. Snímky z komerčných družíc napr. Spot a Ikonos sa využívajú zriedkavejšie, ale ich výhodou je, že produkujú snímky s väčším priestorovým rozlíšením.

V posledných rokoch boli vydané na Slovensku dva významné diela v oblasti využívania satelitov v lesníctve. Prvé dielo nesie názov *Meniace sa Slovensko očami satelitov* [1], v ktorom autori analyzovali viacero zmien z temporálneho hľadiska. Napr. zmeny atmosférického počasia a príkonu slnečného žiarenia, zmeny stavov kozmického počasia, zmeny v poľnohospodárskej krajine, zmeny v lesnej krajine, zmeny v ionosfére, hydrosfére a deformácie zemského povrchu z analýz navigačných a gravimetrických satelitov.

Druhé dielo s názvom *Satelity v službách lesa* [2] je akousi zbierkou článkov, v ktorej autori využili rôzne metódy pre výskum v rôznych oblastiach týkajúcich sa lesného porastu. V článkoch autori rozoberali témy: klasifikácia poškodenia lesov Slovenska, porovnanie priebehu rozpadu smrečín na maloplošných chránených územiach a v hospodárskych lesoch, posudzovanie štruktúry a stability horských lesov a podporou DPZ, tvorba údajovej bázy a modelovanie fenológie lesných porastov, validácia nástupu fenologických udalostí bukových porastov, fenológiu dubových a bukových porastov v období 2000 – 2014, vplyv prízemnej vegetácie a podrastu na priebeh fenologickej krivky bukových porastov, stres dubových a bukových porastov suchom a teplom s použitím experimentálnych satelitných snímok Modis, teoretický koncept modelovania primárnej produkcie lesných porastov, stanovenie ročnej primárnej produkcie uhlíka bukových a dubových porastov na Slovensku a informačný systém na hodnotenie stavu lesa zo satelitných snímok.

1.2 Využitie druhovej skladby lesa

Les je možné deliť podľa viacerých kritérií. Vďaka týmto kritériám správcovia lesov majú lepší prehľad o lese, ktorý spravujú a vedia s ním efektívnejšie hospodáriť. O delení lesov z rôznych hľadísk sa píše napr. na webovej stránke Projektu *Lesná pedagogika* [3].

Les sa podľa druhového zloženia delí na rovnorodý a rôznorodý les. Podľa veku sa les delí na rovnoveký a rôznoveký les. V lesníctve sa používa pojem vekový stupeň, ktorý je na porastových mapách farebne odlíšený. Podľa prevládajúceho využitia, funkcie lesa sa les delí na hospodársky, ochranný a les osobitného určenia. Z pohľadu vlastníctva sa lesy delia na štátne, súkromné, družstevné, cirkevné, mestské, obecné, neurčiteľné (nemajú určené vlastníctvo). Lesy tiež môžu vlastníť urbáre (urbár - druh pozemkovej knihy), spoločnosti a komposesoráty.

Subjektom spravujúcim lesy pre lepší prehľad druhového zloženia lesov, vekovej štruktúry lesov, veľkosti lesných plôch a ich polohu slúžia lesnícke mapy a hospodárske knihy. Plochy lesov sú od najväčších po najmenšie hierarchicky usporiadané: oddelenie, diel, porastová skupina a etáž. Jednotky plochy sú udávané v hektároch.

Les môže mať rôzne druhové zloženie. Zmiešaný les je prirodzený a preto tvorí väčšinu územia lesov v Českej republike. V hospodárskych lesoch veľa plôch zaberajú monokultúry, pretože boli vysádzané umelo. Ale aj napriek tomu v hospodárskych lesoch tvoria monokultúry menšinu, pretože čelia náletovým druhom drevín a tiež semennej banke pôvodného lesa, ktorá je uložená v pôde.

1.3 Vymedzenie oblasti výskumnej témy diplomovej práce

Cieľom práce je nájsť vhodnú metodiku, ktorá dokáže z dát optických družíc, čo najpresnejšie klasifikovať druhové zloženie drevín na území lesov.

1.4 Základný popis výskumných otázok, ktoré pripadajú v úvahu pre spracovanie v diplomovej práci

V ktorom kanáli (vlnovej dĺžke) je najlepšie rozoznať dub od buka?

Aký je najvhodnejší výber kombinácie kanálov?

V ktorom vegetačnom období je najlepšie rozoznať dub od buka?

Použitie ktorého vegetačného indexu je najvhodnejšie pre odlíšenie dubu od buka?

Je vhodnejšie použiť vegetačné indexy, v ktorých sa používajú kanály R a NIR alebo je vhodnejšie použiť vegetačné indexy s kanálmi R a B?

Je lepšie použiť riadenú alebo neriadenú klasifikáciu?

Je lepšie použiť pixelovú alebo objektovú klasifikáciu?

Použitie ktorého diskriminačného klasifikátora je najvhodnejšie pre klasifikáciu drevín?

2 Literárne rešerše vzťahujúce sa k danej úlohe

V tejto kapitole sa nachádzajú rešerše prác k danej úlohe, v ktorých sa nachádza opis územia výskumu, počet skúmaných druhov drevín, použité družice a ich kanály a použitá metóda.

Immitzer a kol. (2012) [4] si vybrali územie výskumu v Rakúsku v Burgenlande. Jedná sa o zmiešaný rôznorodý les. Terén leží v predhorí v nadmorskej výške 290 až 670 m.n.m. Skúmali 10 druhov drevín.

Čo sa týka využitia kanálov autori uvádzajú, že pre vysokú koreláciu kanálov zo satelitu WV-2 (World View-2) najväčšie množstvo informácie nesie kombinácia kanálov C (Coastal), G (Green), R (Red), NIR1 (Near Infrared). Ďalej autori v práci tvrdia, že kanál RE (Red Edge) odlišuje zdravé stromy od stromov, ktoré postihli nejaké choroby a odlišuje stromy podľa veku a aj druhu. Vo viditeľnom pásme najväčšie rozdiely vidieť v zelenom a žltom pásme. Avšak všeobecne najväčšie rozdiely sú v NIR pásmach. Buk sa viac odlišuje v niektorých pásmach od ostatných drevín ako v iných pásmach a to výrazne v pásmach NIR1 a NIR2. V pásme NIR2 na rozdiel od pásma NIR1 je snímaný povrch v o niečo vyššej vlnovej dĺžke a je odolnejší voči atmosférickým vplyvom a preto je vhodnejšie na skúmanie biomasy podľa autorov tohto článku.

Čo sa týka vhodnosti využitia metód na základe výsledkov klasifikácie tvrdia, že metódy RF (metóda Random Forest) a LDA (Linear Discriminant Analysis) sú vhodnejšie ako metódy MDA (mean decrease in accuracy), MDG (mean decrease in Gini), MDFC (mean discriminant function coefficients) a Wilks' Lambda pre skúmanie druhového zloženia lesov. Na dáta aplikovali iteratívne 500 krát metódu LDA. V LDA je vyššia presnosť pri použití 4 kanálov ako 8 kanálov. V ich práci aplikovali aj ďalšie klasifikátory: maximum likelihood, MD (Mahalanobis distance), SAM (spectral angle mapper), SVM (support vector machine), SID (spectral information divergence), NN (neural network).

V tej istej práci celková presnosť v RF (pri 20 iteráciách, 10 druhov drevín, objektivej klasifikácii) najlepšie vyšla pri kombinácii kanálov C, G, R, NIR1 (best classification result RF) a to 0,792. Celková presnosť LDA najlepšie vyšla pri kombinácii kanálov B (Blue band), G, R, NIR1 (best classification result LDA a MDA) a to 0,790. Avšak podľa spektrálnych príznakov opísaných v tomto článku autori považujú kanály NIR1, NIR2, RE, G ako vhodné kanály pre použitie vhodných metód na odlíšenie dubu od buka. Najvyššia užívateľská presnosť vyšla pri objektivej klasifikácii 4 druhov drevín (8 kanálov, Worldview-2). Užívateľská aj výrobná presnosť vychádza cez 90% aj u listnatých aj ihličnatých druhov drevín. Správna klasifikácia bola 95,9% s Kappa indexom 0,945. Výrobná presnosť buka vyšla 98,4% (užívateľská 98%) a duba 97,4%.

Verlič a kol. (2014) [5] sa vo svojom výskume zamerali na zmiešaný heterogénny mestský prírodný les Tivoli, Rožnik a Šišenski hrib (kopec) v Ljubljane v Slovinsku.

Územie výskumu je kompaktné s rozlohou 459 ha a s nadmorskou výškou 295 až 429 m.n.m. Bolo skúmaných 5 druhov drevín.

Autori tvrdia, že im vyšla vyššia OA (celková presnosť) klasifikácie z 8 kanálov (WV-2), ako len zo 4 pôvodných kanálov (WV-2). V práci píšú, že podľa Mean spectral signatures (obr.5) a podľa výsledkov z box-and-whiskers plots (obr.6), by mali byť na skúmanie druhového zloženia drevín najvhodnejšie kanály RE, NIR1, NIR2 a G. Avšak z aplikácie metódy PCA (Principal Component Analysis) na 8 pôvodných kanáloch WV-2 vyšlo, že najviac informácie nesú kanály RE, NIR1, NIR2. Najväčšie množstvo informácie získala prvá komponenta PCA z kanálov NIR1 a NIR2.

Autori v práci porovnávali dve metódy OBIA (object-based image analysis) a PCA. V prípade OBIA išlo o dva hlavné procesy segmentáciu a klasifikáciu. V prípade metódy PCA sa využilo 8 pôvodných snímok v kombinácii s dátami leteckého laserového skenovania a RE NDVI (Band Red-Edge normalized difference vegetation index).

Celková presnosť klasifikácie vyšla 58% a Kappa koeficient 0,431. Výrobná presnosť duba vyšla 70% a buka len 38%. Uživateľská presnosť duba vyšla 47% a buka 64%.

Chinsu Lin a kol. (2015) [6] si vybrali ako územie výskumu dažďový les v centrálnej časti Taiwanu. Skúmali 40 druhov drevín.

Autori použili snímky z družice QB (QuickBird) a pomocou nich vypočítali vegetačné indexy ARVI (atmospherically resistant vegetation index), VARI (visible atmospherically resistant index) a EVI (enhance vegetation index). Predpokladajú, že najvhodnejšie sú modré a zelené pásma na skúmanie druhového zloženia drevín. Klasifikácia z VIs im vyšla s nižšou klasifikačnou presnosťou ako klasifikácia HMS snímok, pretože každý z VIs používa iba časť spektrálnych príznakov z HMS.

Autori urobili v práci pixelovú klasifikáciu metódou Maximum Likelihood Classification a následne na tie isté dáta aplikovali oddelene metódy MD, SAM, SVM, SID a NN.

Pri klasifikácii 40 druhov drevín vyšiel celkový kappa koeficient 0,58. Po klasifikácii 5 VIs vyšiel celkový kappa koeficient len 0,48. V tomto článku autori využili okrem spektrálneho príznaku aj texturálny príznak, vďaka čomu autori dosiahli pri skombinovaní HMS, VIs, SpecTex (HMS spectral-spatial texture image) OKC viac ako 0,98. Takže môžeme vidieť, že texturálny príznak môže zvýšiť hodnotu OKC.

A.Carleer & E. Wolff (2004) [7] si vybrali ako územie výskumu časť Brussels-Capital Sonian Forest. Skúmaných bolo 11 druhov drevín.

V tejto práci autorom vyšla najvyššia OA klasifikácie kombináciou pôvodných kanálov (R, G, B, NIR), NDVI a prvou komponentou PCA.

Autori vo svojej práci urobili pixelovú klasifikáciu metódou Maximum Likelihood Classification na kanáloch pôvodných HMS, NDVI a PCA. S cieľom znížiť vnútornú odchýlku tried aplikovali mean filter do všetkých pôvodných aj nových kanálov.

Aplikácia mean filtra na kanále obraz vyhladí a lepšie vidieť rozdiely medzi triedami, ale horšie v rámci tried. Na elimináciu salt-and-pepper efektu bol použitý modal filter. Klasifikácia filtrovaného obrazu vyšla lepšie ako nefiltrovaného obrazu.

Celková presnosť klasifikácie vyšla 0,8579 a Kappa index 0,838. U duba vyšla klasifikačná presnosť 0,878. U mladého buka vyšla klasifikačná presnosť 0,977, u starého buka 1,00 a u purpurového buka 0,862. Autori na záver dodávajú, že dub a starší buk sa zle odlišujú v neriadenej klasifikácii kvôli ich spektrálnej podobnosti.

Krahwinkler & Rossmann (2010) [8] si vybrali územie výskumu v lokalite severo-východne od mesta Arnsberg v Nemecku. Skúmaných bolo 6 druhov drevín.

Na základe výsledkov v práci autori tvrdia, že pri leteckých a družicových SPOT snímkoch sú pre skúmanie buku (beech) najvhodnejšie nové kanály IR-R, IR-G, IR-B. Pre klasifikáciu buku (oak) je najvhodnejšie použiť IR-G.

Autori vo svojej práci poukazujú na PDA (penalized discriminant analysis). PDA produkuje lineárne kombinácie kanálov, to poukazuje na to ako pomocou komponent predictor vector contribute zadefinovať diskriminačné pravidlo. V práci ako klasifikačnú metódu použili rozhodovací strom založený na pomere DN hodnôt jednotlivých kanálov.

Na oddelenie území bez lesa a lesa s tieňom od územia pokrytým lesom bol využitý DCM (digital canopy model), celkový jas a rozdiely IR-R, G-B.

Celková presnosť klasifikácie vyšla 0,78. Klasifikačná presnosť duba vyšla 0,743 a buka 0,797.

Immitzer a kol. (2016) [9] svoj výskum robili na území Ebersberg a Altötting, lokalizované východne od Mníchova v Nemecku. Les bol rôznorodý s dominanciou smreku. Skúmaných bolo 12 druhov drevín.

Autori článku si myslia, že dáta z družíc L-8 (Landsat-8) a S-2 (Sentinel-2) nemajú dostatočné priestorové rozlíšenie na skúmanie druhového zloženia rôznorodého lesa.

Autori vo svojej práci využili na dáta individuálnu segmentáciu použitím automatizovaných procedúr a mean shift algoritmu. Tiež využili metódu RF.

U dát z WorldView-2 vyšla OA 0,744 a Kappa index 0,691. Pre dub vyšla spracovateľská presnosť 0,559 a užívateľská presnosť 0,589. Pre buk vyšla spracovateľská presnosť 0,785 a užívateľská presnosť 0,664.

U dát zo Sentinel-2 vyšla OA 0,681 a Kappa index 0,611. Pre dub vyšla spracovateľská presnosť 0,281 a užívateľská presnosť 0,450. Pre buk vyšla spracovateľská presnosť 0,727 a užívateľská presnosť 0,706.

U dát z Landsat-8 vyšla OA 0,494 a Kappa index 0,380. Pre dub vyšla spracovateľská presnosť 0,194 a užívateľská presnosť 0,261. Pre buk vyšla spracovateľská presnosť 0,621 a užívateľská presnosť 0,526.

Bucha (2007) [10] si ako výskumné územie vybral celé zalesnené územie Slovenska. Skúmaných bolo 15 druhov drevín.

Autor vo svojej práci tvrdí, že lepšie výsledky klasifikácie dosiahol použitím nového kanálu vytvoreného z DTM (digitálny model terénu) v kombinácii s poznatkami o raste jednotlivých druhov drevín v konkrétnom rozpätí nadmorských výšok ako z prvej komponenty PCA z pôvodných HMS kanálov.

V práci bola využitá metóda Maximum Likelihood s Bayassovým klasifikátorom.

Správnosť klasifikácie bola preverená na súbore 412 trénovacích plôch a pohybovala sa v závislosti od scény v rozpätí od 80% do 90%.

3 Prehľad potrebných dát a ich zdrojov

Na aplikáciu danej metódy sa využijú dáta s multispektrálnych družíc Landsat-8 a Sentinel-2. Ako vhodné územie pre výskum boli vybrané lesné porasty v katastroch Osvětimany a Buchlovice v okrese Uherské Hradiště v Českej republike.

Snímky z Landsat-8 je možné získať napr. od U.S. Geological Survey. [a] Snímky Sentinel-2 je možné zadarmo stiahnuť z webovej stránky Európskej vesmírnej agentúry z portálu Sentinel-2 Pre-Operations Data Hub. [b]

Podklady pre kontrolu správnosti klasifikácie sú získané z hospodárskych kníh od Lesného Družstva Osvětimany a od Lesov Českej republiky s platnosťou na roky 2015 – 2024.

4 Návrh metódy

Cieľom práce je navrhnúť metódu, použitím ktorej dosiahne klasifikácia duba a buka vyššiu celkovú presnosť ako pri iných metódach, kde boli použité multispektrálne snímky priestorového rozlíšenia pixlu min. 10 m.

Najprv sa vykoná výber, z ktorých optických družíc sa použijú dáta pre túto prácu. Následne sa vyberú vhodné snímky z 3 ročných období a to z jari, leta a jesene. Podľa Buchu a kol. [2] dub a buk sa dá v rôznych ročných obdobiach najlepšie odlišovať v rôznych kanáloch.

Na začiatku je potrebné pripraviť dáta. Potom urobiť zo snímok výrezy výskumného územia. Následne sa odfiltrujú u výrezov ručne oblaky, tieňe a podobne ako to odporúča Bucha [10]. Aplikáciou NDVI a SAVI sa oddelí presvitajúca pôda od vegetácie ako to odporúča Huete A. [11].

Potom sa na základe literatúry uvedenej v rešerši vyberie najvhodnejšia kombinácia kanálov v kombinácii s najvhodnejším klasifikátorom pre skúmanie duba a buka. Vyberá sa z pôvodných kanálov, z nových kanálov vypočítaných rozdielom dvoch pôvodných kanálov, z vegetačných indexov, z komponentov PCA a z kanálu vytvoreného z výškového modelu terénu, tak ako to odporúčajú vo svojich prácach Immitzer [4] a Verlič [5].

Aplikuje sa Mean filter jednotlivo na všetky kanály. Obráz to vyhladí a lepšie vidieť rozdiely medzi triedami, ale horšie v rámci tried. Vďaka tomu sa bude dať určiť presnejšia hranica medzi jednotlivými triedami. Tak ako to odporúčajú A. Carleer & E. Wolff [17].

Tento postup skúsime zopakovať na snímkach z rôznych ročných období, aby bol viditeľný vplyv fenologických zmien vegetácie počas roka na spektrálne príznaky.

Keďže na skúmanom území sa vyskytujú okrem duba a buka aj hrab obyčajný (HB), topoľ osikový (OS), smrek obyčajný (SM) a smrekovec opadavý (MD), potom taktiež aj pre tieto dreviny vytvoríme klasifikačné triedy. Inak by nám mohla vyjsť dosť vysoká klasifikačná chyba kvôli spektrálne širokému rozsahu histogramu triedy „ostatné dreviny“.

Po vybraní vhodnej kombinácii kanálov a zvolení k nim vhodnej diskriminačnej analýzy sa vo vhodnom softvéri urobí klasifikácia vybratých snímok. Následne sa výsledky klasifikácie porovnajú a vyberú sa iba tie pixle, ktoré boli klasifikované do rovnakej triedy aspoň u väčšiny snímok. Tieto pixle budú tvoriť základ pre vytvorenie nových umelých trénovacích množín. Po vytvorení umelých trénovacích množín sa klasifikácia zopakuje s rovnakou diskriminačnou analýzou na snímky.

Následne sa vytvorí pre každú klasifikovanú vrstvu chybová matica, kde okrem klasifikačnej vrstvy bude vstupovať aj referenčná vrstva. Pomocou celkovej presnosti sa porovnajú všetky klasifikované vrstvy a zistí sa, či umelé trénovacie množiny dosiahli lepšiu klasifikačnú presnosť.

Pre kontrolu či boli správne vybrané v prvom kroku prirodzené trénovacie množiny, boli vytvorené aj testovacie množiny, pomocou ktorých boli klasifikované snímky.

Metóda v tejto práci je na postavená na jednoduchšej myšlienke, že čím viac je jeden pixel na rôznych snímkach klasifikovaný do tejto istej triedy, tým je väčšia pravdepodobnosť, že bol klasifikovaný správne.

Články o umelých, alebo modifikovaných trénovacích množinách pixlov neboli nájdené medzi internetovými zdrojmi a preto sa vynára široká škála otázok o výskume v tejto oblasti.

5 Návrh postupu práce

5.1 Výber vhodného softvéru na spracovanie dát

Pred začatím práce je potrebné zvoliť si vhodný softvér. Dostupný softvér je PCI Geomatica (verzia 2007), ENVI (verzia 4.6) a ArcGIS (verzia 10.4.1).

5.2 Úprava mapových podkladov

Mapové podklady musia spĺňať určité kritéria. V prípade, že vznikli digitalizáciou podkladov z papierovej podoby, ohnisko premietania nesmie byť stredové, pretože zdigitalizovaný mapový podklad bude mať v strede nulové skreslenie, ale od stredu smerom do strán sa bude skreslenie zväčšovať. Preto sa odporúča skenovanie.

Pred začatím georeferencovania je potrebné zistiť rozmery jedného pixlu mapového podkladu v metroch. Veľkosť jedného pixlu na mapovom podklade by mal byť rovný, alebo menší ako pixel z družicovej snímky.

5.3 Georeferencovanie

Základom georeferencovania mapových podkladov je zvolenie si vhodného softvéru. Je možné použiť napr. ArcGIS, QGIS alebo PCI Geomatica.

Program PCI Geomatica - OrthoEngine nie je vhodné použiť v tomto prípade pretože nie je možné v ňom načítať WMS vrstvu. Georeferencovanie porastovej mapy v tomto prípade nie je robené pomocou satelitných snímok, ale podľa WMS ZM 1:10 000 (Základná mapa Českej republiky 1:10 000), pretože nie je možné nájsť na snímkach vlicovacie body.

Najprv sa v zvolenom softvéri, v tomto prípade v programe ArcGIS, georeferencujú skeny získaných porastových máp podľa WMS vrstvy ZM 1:10 000 získanej z geoportálu ČÚZK (Český úrad zeměměřický a katastrální). Porastové mapy boli pôvodne zhotovené v súradnicovom systéme S-JTSK (Systém jednotné trigonometrické sítě katastrální). WMS vrstva ZM 1:10 000 je uložená v geoportáli ČÚZK v súradnicovom systéme WGS84 (World Geodetic System 1984). Túto WMS vrstvu je nutné pretransformovať do WGS84 UTM 33N.

Najprv sa v programe ArcGIS nanesie na WMS vrstvu sken porastovej mapy. Následne sa pomocou nástroja *Georeferencing* postupne pridávajú vlicovacie body rovnomerne rozmiestnené na skene porastovej mapy. Potom sa vo *View Link Table* skontroluje veľkosť RMSE chyby u jednotlivých vlicovacích bodov. Následne sa vypnú body, ktoré majú najväčšiu RMSE chybu a v ich okolí sa vyberú miesta vhodné pre zadanie nových vlicovacích bodov.

Najväčšiu RMSE chybu dosahovali vlicovacie body, ktoré ležali na miestach, kde sa pretínala lesná cesta s vrstevnicou a na rozvodiach menších potokov. Tieto body boli vypnuté a nahradené inými vlicovacími bodmi v ich okolí, ktoré boli vhodnejšie na

zadanie vlicovacích bodov. Najmenšiu RMSE chybu mali body ležiace na križovatkách ciest a na miestach, kde sa pretínala cesta s riekou.

Je vhodné použiť metódu prevzorkovania najbližšieho suseda, pretože zachováva diskkrétne hodnoty, aby sa neprepočítavali hodnoty rastrov. Pre georeferencovanie je táto metóda najvhodnejšia. Rektifikované dáta sa uložia do geofile databázy.

5.4 Výber vhodných snímok

Výber snímok z Landsat-8 a Sentinel-2 je vhodné voliť tak, aby boli zo začiatku, vrcholu a konca vegetačného obdobia vybraných druhov drevín. Snímky, na ktorých oblaky, ich tieň a opar pokrývajú viac ako 20% rozlohy územia snímky, nie sú vhodné pre výskum vegetácie.

Snímky z Landsat-7 sú zhotovené pomocou senzora ETM-SCM-OFF na rozdiel od Landsat-8, v ktorom je zabudovaný senzor OLI. Na snímkach z Landsat-7 sú čierne pásy, ktoré vznikli pri snímkaní. Pre ďalšiu prácu so snímkami je potrebné odstrániť tieto pásy. Aj preto bol uprednostnený Landsat-8.

5.5 Atmosférická korekcia

V prípade Landsat-8 dáta budú stiahnuté v úrovni spracovania Level-1 High-Level, takže s atmosférickou korekciou.

V prípade Sentinel-2 dáta je možné stiahnuť v úrovni spracovania Level-1, takže bez atmosférickej korekcie. Dáta v úrovni spracovania Level-2 sú s atmosférickou korekciou, ale nie sú voľne dostupné.

5.6 Topografická korekcia

V prípade Landsat-8 dáta budú stiahnuté v úrovni spracovania Level-1 High-Level, takže aj s topografickou korekciou.

V prípade Sentinel-2 dáta majú topografickú korekciu urobenú pomocou hrubého DMR.

5.7 Odfiltrovanie oblakov, ich tieňov a oparu

Oblačnosť, ich tieň a opar *Bucha* [10] odporúča odfiltrovať ručne, podobne ako to uviedol vo svojej práci. Predovšetkým opar je veľmi ťažko odstrániť automaticky, pretože je veľmi ťažko rozlíšiteľný na snímkach. Najspoľahlivejšie je v tomto prípade rozoznať opar pomocou ľudského oka a odfiltrovať ho ručne.

5.8 Rozoznanie pixlov pokrytých vegetáciou a holou zemou

Na snímke sa aplikujú matematické operácie na výpočet NDVI a SAVI pre oddelenie súvislej vrstvy vegetácie od presvitajúcej pôdy.

V softvéri ArcGIS sa použije nástroj *Raster Calculator*, cez ktorý sa vypočíta NDVI a SAVI.

NDVI je vegetačný index, ktorý potlačuje vplyv topografie a osvetlenia (osvetlená strana reliéfu/vegetácie a reliéf/vegetácia v tieni). Index nadobúda rozsah hodnôt od -1 do +1. Voda a oblačnosť nadobúdajú záporné hodnoty. Čím je hustejšia vegetácia, tým má vyššiu kladnú hodnotu. Pôda bez vegetácie nadobúda hodnoty okolo 0.

$$NDVI = (NIR - R) / (NIR + R)$$

SAVI je vegetačný index, ktorý berie viac do úvahy vplyv pôdy. Predstava je taká, že celý pixel by mal byť pokrytý vegetáciou, ale v skutočnosti môže cez vegetáciu presvitať holá pôda. Index nadobúda hodnoty od -1 do +1. Čím je hodnota nižšia, tým viac presvita holá pôda. Čím je hodnota vyššia, tým viac je vegetácia hustejšia.

Za premennú L sa môžu dosadiť hodnoty od 0 do 1. Keď má skúmaná lokalita hustý vegetačný pokryv, tak sa za premennú L dosadí 0. Keď je skúmaná lokalita pokrytá holou pôdou, tak sa za premennú L dosadí 1. Väčšinou sa za premennú L dosadí hodnota 0,5, pretože sa skúma územie, kde sa nachádza aj vegetácia s hustým pokryvom, s riedkym pokryvom, aj holá pôda.

$$SAVI = (NIR - R) / (NIR + R + L) * (1 + L)$$

5.9 Výber a vyhotovenie diskriminačnej analýzy a kanálov

Na základe literárnej rešerše je potrebné vybrať si diskriminačnú analýzu a k nej vhodné kanály pre skúmanie vybraných druhov drevín. Výber bude robený na základe nasledovných informácií:

Immitzer a kol. (2012) [12] [4] podľa spektrálnych príznakov opísaných v tomto článku považujú kanály **NIR1, NIR2, RE, G** ako vhodné kanály pri použití vhodných metód na odlíšenie duba od buka. (MLC)

Verlič a kol. (2014) [13] [5] v práci píše, že podľa Mean spectral signatures (obr.5) a podľa výsledkov z box-and-whiskers plots (obr.6) by mali byť na skúmanie druhového zloženia drevín najvhodnejšie kanály **RE, NIR1, NIR2 a G**. Avšak z aplikácie metódy PCA (Principal Component Analysis) na 8 pôvodných kanálov WV-2 vyšlo, že najviac informácie nesú kanály **RE, NIR1, NIR2**. Najväčšie množstvo informácie získala prvá komponenta PCA z kanálov **NIR1 a NIR2**. (MLC)

Chinsu Lin a kol. (2015) [15] [6] po aplikácii vhodných metód napísali, že najvhodnejšie kanály na skúmanie druhového zloženia drevín je **B a G**. (MLC)

A.Carleer & E. Wolff (2004) [17] [7] tvrdia, že v tejto práci vyšla najvyššia OA klasifikácie kombináciou pôvodných kanálov (**R, G, B, NIR**), **NDVI** a prvou komponentou **PCA** pri použití vhodných metód. (MLC)

*Krahwinkler & Rossmann (2010) [19] [8] na základe výsledkov v práci autori tvrdia, že pri leteckých a družicových SPOT snímkoch sú pre skúmanie buka (beech) najvhodnejšie nové kanály **IR-R**, **IR-G**, **IR-B**. Pre klasifikáciu duba (oak) je najvhodnejšie použiť **IR-G**. (PDA)*

*Bucha (2007) [21] [10] vo svojej práci tvrdí, že lepšie výsledky klasifikácie dosiahol použitím nového kanálu vytvoreného z **DTM** v kombinácii s poznatkami o raste jednotlivých druhov drevín v konkrétnom rozpätí nadmorských výšok, ako z prvej komponenty PCA. V tejto práci použil ako kanále komponenty PCA 1, 2, 3 a DTM. (MLC)*

Poznámka: V zátvorkách za odstavcami sú skratky metód použité v danej práci.

5.10 Výber klasifikačných tried, trénovacích a testovacích vzoriek pixlov

Po zgeoreferencovaní skenov lesníckych máp je vhodné pracovať už len s rektifikovanými dátami.

V hospodárskych knihách je územie daného katastru hierarchicky rozdelené na oddelenia, diele, porastové skupiny a v niektorých špecifických prípadoch aj etáže. Každá takáto jednotka obsahuje údaje koľko percent jej územia zaberá konkrétna drevina a ku každému údaju je pridaný aj priestorový údaj v hektároch.

Na základe týchto údajov z hospodárskych kníh, by malo byť možné nájsť dostatočne veľké územia na výskum. Pre prácu so snímkami Landsat-8 je vhodné nájsť druhovo homogénne územie a so súvislým vegetačným pokryvom, ktorého aspoň 95% plochy pokrýva jeden druh dreviny. Zároveň by na tomto území mali byť dreviny rovnakej vekovej kategórie. Malo by ísť o územie, ktoré má rozlohu aspoň 5 ha. Avšak ideálne územie by malo mať viac ako 10 ha.

V GIS softvéroch sa dá vrstva snímku jedného kanálu spriesvitniť tak, aby bolo možné vidieť pod ňou vrstvu skenu lesníckej mapy. Z toho sa dá následne usúdiť množstvo pixlov nachádzajúcich sa na danom homogénnom území.

Vstupným parametrom pre počet pixlov vo vnútri danej plochy nie je len veľkosť plochy, ale aj tvar polygónu, počet polygónov tvoriacich danú územnú jednotku, súbor vlastností enklávnych polygónov inej územnej jednotky a natočenie plochy referenčnej vrstvy v snímkam pri georeferencovaní.

5.11 Maximum Likelihood Classification

Maximum Likelihood Classifier (MLC) je jedna z najpopulárnejších klasifikačných metód v DPZ, v ktorej je pixel s maximálnou pravdepodobnosťou zaradený do príslušnej triedy. [12]

Pri použití MLC v softvéri PCI Geomatica (verzia 2007) je možné nastaviť jediný parameter a to, že klasifikátor môže zaradiť pixle do nulovej triedy (*With NULL class*).

V prípade použitia MLC v softvéri ENVI (verzia 4.6) je možné nastaviť tieto parametre: prah pravdepodobnosti (*Set Probability Threshold*) a faktor dátovej stupnice (*Data Scale Factor*).

Pri použití MLC v softvéri ArcGIS (verzia 10.4.1) je možné nastaviť nasledovné parametre. *Reject Fraction* je parameter, v ktorom je možné v percentách nastaviť aké množstvo pixlov s najnižšou mierou pravdepodobnosti, že budú klasifikované správne, nebudú klasifikované do žiadnej triedy. Ďalším parametrom je A priori pravdepodobnosť (*A priori probabilities*), v ktorom je možné vybrať jednu z troch možností: 1. Všetky triedy budú mať rovnakú A priori pravdepodobnosť, 2. A priori pravdepodobnosť bude úmerná počtu buniek v každej triede vzhľadom na celkový počet buniek odoberatých vo všetkých triedach v súbore .gsg s trénovacími vzorkami. 3. A priori pravdepodobnosť bude priradená každej triede z vstupného ASCII súboru. V tomto softvéri je možné urobiť aj výstupný raster *Output confidence raster*, ktorý vygeneruje raster obsahujúce údaje o dôveryhodnosti klasifikovaného obrazu. V tomto výstupe sú pixle obsahujúce jednu zo 14 tried. Pixle zaradené do triedy 1 boli označené, že nesú najvyššiu dôveryhodnosť. [13]

5.12 Chybová matica

Chybová matica (Confusion matrix, Error matrix) slúži na určenie presnosti klasifikácie. V matici sa porovnáva klasifikovaná vrstva s referenčnou vrstvou pomocou náhodných bodov. Sila chybovej matice spočíva v tom, že identifikuje charakter klasifikačných chýb a tak isto aj ich množstvo. [14]

V softvéroch PCI Geomatica (verzia 2007) a ENVI (verzia 4.6) je chybová matica vypočítaná automaticky pri klasifikácii, nachádza sa v správe o prebehnutnej klasifikácii. Stačí si pri klasifikácii zaškrtnúť možnosť vygenerovať report.

Chybová matica v softvéri ArcGIS (verzia 10.4.1) sa vypočíta pomocou troch nástrojov. [15]

Najprv sa pomocou nástroja *Create Accuracy Assessment Points* vytvorí náhodné body na posúdenie presnosti. Do tohto nástroja sa ako vstupná vrstva vkladá klasifikovaná vrstva, ktorú je potrebné vložiť vo forme rastra.

Následne sa použije nástroj *Update Accuracy Assessment Points*, do ktorého sa vloží výstup z predchádzajúceho nástroja. Ďalším vstupom do tohto nástroja je referenčná vrstva (Ground truth). Tiež je potrebné ju vložiť vo forme rastra.

Posledným nástrojom je *Compute Confusion*, pomocou ktorého sa vypočíta chybová matica. V tomto nástroji je potrebné v atribútovej tabuľke orezať len tie záznamy, ktoré neobsahujú hodnotu „-1“. Hodnotu „-1“ obsahujú body, ktoré na nachádzajú mimo referenčnej vrstvy. Tiež je potrebné si dať pozor na koncovku výsledného formátu a zmeniť na .dbf.

Obr. č. 1: Príklad chybovej matice

	c_1	c_2	c_3	Total	U_Accuracy	Kappa
c_1	49	4	4	57	0.8594	0
c_2	2	40	2	44	0.9091	0
c_3	3	3	59	65	0.9077	0
Total	54	47	65	166	0	0
P_Accuracy	0.9074	0.8511	0.9077	0	0.8916	0
Kappa	0	0	0	0	0	0.8357

Zdroj: ArcGIS for Desktop [15]

6 Priebeh práce a výpočty

6.1 Výber vhodného softvéru na spracovanie dát

Potrebné bolo zvoliť softvér, v ktorom sa dajú georeferencovať skeny porastových máp, vytvárať tréningové a testovacie množiny, klasifikovať snímky a vytvárať chybové matice.

Z dostupných softvérov PCI Geomatica (verzia 2007), ENVI (verzia 4.6) a ArcGIS (verzia 10.4.1) bol zvolený ArcGIS. V softvéroch PCI Geomatica a ENVI oproti ArcGISu je proces klasifikácie oveľa automatizovanejší a je možné nastaviť oveľa viacej možností v nastaveniach parametroch v jednotlivých klasifikačných nástrojoch, avšak ArcGIS od verzie 10.4.1 ponúka dostatočnú širokú paletu nástrojov a ich parametrov na vyriešenie zadania tejto práce.

Pre pomocné výpočty náročnejšie na funkcie bol použitý softvér Microsoft Excel 2010.

6.2 Úprava mapových podkladov

Porastovú mapu k.ú. Buchlovice bola získaná v podobe skenov v digitálnej podobe, ktoré vznikli skenovaním z originálnej tlačenej mapy. Veľkosť pixlov skenov katastra Buchlovice je 0,8364 m (1m). Pri práci so skenmi mapy sa muselo počítať s chybou, ktorá vyplýva z fyzikálnych vlastností papierovej mapy. Chyba je na rôznych miestach iná od 0,5 pixla do 3 pixlov, čiže od 0,5 do 3 metrov. Táto chyba je v norme, keďže družicové dáta Sentinelu majú priestorové rozlíšenie od 10 m. Na túto chybu som narazil pri odstraňovaní bielych pásov zo skenov porastovej mapy.

Odstraňovanie bielych pásov zo skenov bolo urobené v softvéri Zoner Photo Studio 17.

Porastová mapa k.ú. Osvetimany bola obdržaná v digitálnej podobe v mierke 1 : 23816. Veľkosť pixlov mapy katastra Osvetimany je 6,27 m (6m). Túto mapu nebolo potrebné pred georeferencovaním nijak upravovať.

Sken porastovej mapy k.ú. Buchlovice z papierovej mapy má veľkosť pixlov 0,96 m (1m).

6.3 Georeferencovanie

Lokalita s porastom duba a buka pri georeferencovaní obrázka digitálnej mapy *Osvetimany* pri 12 vlicovacích bodoch dosiahla RMSE chybu 13,21 m a pri 7 vlicovacích bodoch 3,34 m.

Lokalita s porastom duba a buka pri georeferencovaní skenu *Osvetimany* pri 9 vlicovacích bodoch dosiahla RMSE chybu 11,7 m.

Lokalita s porastom buka pri georeferencovaní skenu *Buchlovice 2a* pri 9 vlicovacích bodoch dosiahla RMSE chybu 7,63 m a pri 6 vlicovacích bodoch 3,87 m.

Lokalita s porastom duba pri georeferencovaní skenu *Buchlovice3a* pri 9 vlicovacích bodoch dosiahla RMSE chybu 6,05 m a pri 7 vlicovacích bodoch 4,33 m.

V prípade k.ú. Osvětimany sa v ďalšom postupe použije rektifikovaná vrstva z obrázka digitálnej mapy zo 7 vlicovacích bodov s RMSE chybou 3,34. A v prípade k.ú. Buchlovice sa v prípade obidvoch skenov použijú rektifikované vrstvy z 9 vlicovacích bodov s RMSE chybou 7,63 m a 6,05 m.

6.4 Výber vhodných snímok

V prípade Landsat-8 boli vybrané 2 vhodné snímky zo začiatku vegetačného obdobia (10.3.2014 so 6% oblačnosťou, 20.3.2015 s 0% oblačnosťou), 4 vhodné snímky z vrcholu vegetačného obdobia (3.7.2015 s 3% oblačnosťou, 19.7.2015 s 3% oblačnosťou, 21.7.2015 s 8% oblačnosťou, 11.8.2015 s 12% oblačnosťou), 4 vhodné snímky z konca vegetačného obdobia (6.9.2013 s 0% oblačnosťou, 1.10.2013 s 2% oblačnosťou, 30.9.2016 s 3% oblačnosťou, 7.9.2016 so 7% oblačnosťou).

6.5 Atmosférická korekcia

Snímky z družice Landsat-8 boli stiahnuté už s atmosférickou korekciou a preto nebolo potrebné robiť atmosférickú korekciu.

Keby sa v tejto práci použili aj dáta zo Sentinel-2, atmosférická korekcia by bola robená v softvéri ENVI pomocou nástroja *FLAASH*, pri ktorej by sa transformovali hodnoty pixlov snímky z TOA do BOA.

6.6 Topografická korekcia

Snímky z družice Landsat-8 boli stiahnuté už s topografickou korekciou a preto nebolo potrebné robiť topografickú korekciu.

Ak by sa v tejto práci použili aj dáta zo Sentinel-2, mohla by byť ponechaná topografická korekcia, ktorú už získané dáta obsahovali t.j. na hrubom DMR modeli. Ak by táto topografická korekcia nestačila, bolo by možné ju urobiť na jemnejšom DMR modeli.

6.7 Odfiltrovanie oblakov, tieňov a oparu

V prípade snímok z družice Landsat-8 boli uprednostnené snímky, ktoré vo výskumnom území neobsahovali žiadne oblaky, opar a tieň z oblakov.

Ak by nebolo dostupných dostatočné veľké množstvo snímok, ktoré vo výskumnej oblasti neobsahujú oblaky, opar a tiene, tak potom oblačnosť, tiene a opar by mohli byť odfiltrované ručne podobne ako to vo svojej práci urobil *Bucha* [10].

Postup tejto práce by mohol byť urobený v programe ArcGIS. Na snímkach sú zreteľne rozoznateľné oblaky, ich tiene a opar. Najprv by boli pomocou vektorizovania urobené polygóny nad oblakmi, ich tieňmi a oparom. Tieto polygóny by presne nekopírovali hranice týchto objektov, pretože hranicu predovšetkým oparu je len veľmi ťažké určiť. Preto polygóny by boli urobené tak, aby zaberali aj určité územie okolo týchto objektov.

Následne by boli použité nástroje „*Polygon to Raster*“, „*Reclassify*“ a „*Raster Calculator*“, kde by boli zmenené niektoré parametre. Ako výsledná vrstva by vyšiel raster snímky orezaný od oblakov, ich tieňov a oparu. Teda inak povedané, na ich mieste by ostali pixle s hodnotou „NoData“.

6.8 Rozoznanie pixlov pokrytých vegetáciou a holou zemou

Po odfiltrovaní oblakov, ich tieňov a oparu v ďalšej časti by bola rozoznaná pôda, ktorá by nemala dostatočne hustý vegetačný pokryv.

Na snímkach Landsat-8 a Sentinel-2 sa aplikovali matematické operácie na výpočet NDVI a SAVI pre oddelenie súvislej vrstvy vegetácie od presvitajúcej pôdy.

V prípade SAVI boli urobené dva výpočty a to jeden s koeficientom $L=0,5$ a druhý s koeficientom $L=0,7$.

Pri výpočte si bolo treba dať pozor na to, že v prípade Landsat-8 je NIR (5. kanál) a v prípade Sentinel-2 (8. kanál). Kanálu R je rovnako v oboch prípadoch aj Landsat-8 aj Sentinel-2 (4. kanál).

Vrstvy zgeoreferovaná porastová mapa, NDVI, SAVI a tiež google maps ďalej slúžili pri tvorbe tréningových a testovacích množín na určenie toho, ktoré pixle sú pokryté vegetáciou a ktoré nie sú pokryté vegetáciou.

6.9 Výber a vyhotovenie diskriminačnej analýzy a kanálov

Na základe informácií z uvedených rešerší (kapt. 5.10.) v práci bola použitá klasifikácia pomocou Maximum Likelihood Classification.

Keďže bolo pracované so snímkami Landsat-8 a použitá bola metóda MLC, tak zo všetkých 19 kanálov boli vybraté práve tieto štyri základné B, G, R, NIR, pretože navzájom so sebou najmenej korelujú.

Ak by bolo pracované so snímkami iných družíc, tak napr. v prípade WV-2, by boli použité kanále RE, NIR1, NIR2, G, ako to odporúčajú Immitzer a Verlič [4, 5]. Ak by bolo pracované so snímkami z družice S-2, tak by boli použité R, VRE (6-band), NIR, VRE (8A-band), pretože kanály VRE sú určené na skúmanie vegetácie.

6.10 Výber klasifikačných tried, trénovacích a testovacích vzoriek pixlov

Na základe porastovej mapy a hospodárskych kníh k.ú. Buchlovice a Osvětimany bolo možné vyčleniť druhy drevín, ktoré majú na určitých parcelách homogénne zastúpenie. Ide o dreviny buk, dub a smrek.

Na jednotlivých parcelách, na ktorých je z druhového hľadiska homogénne zastúpenie drevín, bolo možné vypožorovať, že na jednotlivých parcelách je rôzne vekové zastúpenie drevín.

V prípade k.ú. Buchlovice v prípade duba bolo možné rozoznať parcely s vekom drevín 81 – 100 rokov s prímесou drevín vo veku 1 – 20 rokov. V prípade buka bolo možné rozoznať parcely s vekom drevín nad 141 rokov s prímесou drevín vo veku 1 – 20 rokov.

V prípade k.ú. Osvětimany v prípade duba bolo možné rozoznať parcely s vekom drevín 81 – 100 rokov s prímесami drevín vo veku 1 – 20 rokov a 121 – 140 rokov. V prípade buka bolo možné rozoznať parcely s vekom drevín 61 – 80 rokov, bez prímеси.

Na obidvoch k.ú. bolo možné rozoznať parcely, ktoré sú pokryté homogénne bukom vo veku 41 – 60 rokov bez prímеси.

V k.ú. Buchlovice sú aj ďalšie parcely, ktoré sú pokryté homogénnym druhom dreviny v homogénnej vekovej kategórii, ale tieto plochy nie sú dostatočne veľké, aby bolo možné do nich vhodne situovať trénovacie a testovacie vzorky. Jedná sa o územie pokryté dubom vo vekových kategóriách 61 – 80 a 101 – 120 rokov s prímесou duba vo vekovej kategórii 1 – 20 rokov. Ďalej ide o územie pokryté bukom vo vekových kategóriách 1 – 20 a 21 – 40 bez prímеси. Nachádza sa tu aj homogénne územie smreka vo vekovej kategórii 81 – 100 rokov.

Na základe týchto informácií bolo zvolených 5 tried:

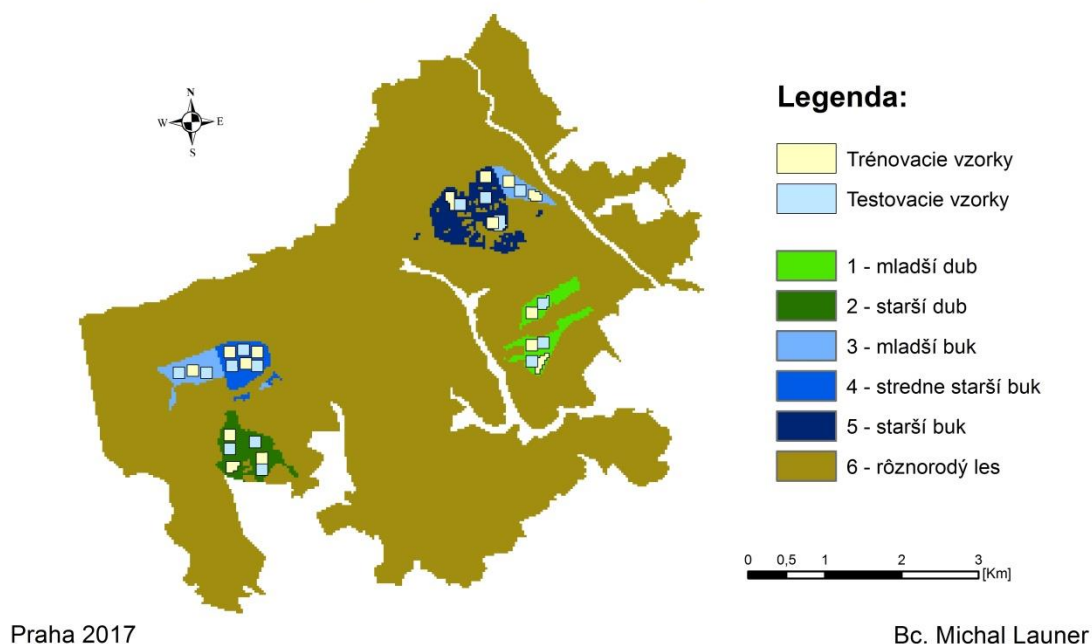
1. Dub vo veku 81 – 100 rokov s prímесou duba vo veku 1 – 20 rokov
2. Dub vo veku 81 – 100 rokov s prímесou duba vo veku 1 – 20 a 121 – 140 rokov
3. Buk vo veku 41 – 60 rokov bez prímеси
4. Buk vo veku 61 – 80 rokov bez prímеси
5. Buk vo veku nad 141 rokov s prímесou buka vo veku 1 – 20 rokov

V prílohe v legende na mapových výstupoch majú tieto triedy pomenovanie:

1. Mladší dub
2. Starší dub
3. Mladší buk
4. Stredne-starší buk
5. Starší buk

Obr. č. 2: Trénovacie a testovacie množiny umiestnené na referenčnej vrstve lesov k.ú. Osvětman a Buchlovíc

Trénovacie a testovacie množiny umiestnené na referenčnej vrstve lesov k.ú. Osvětman a Buchlovíc



Zdroj: autor

6.11 Priebeh klasifikácie

Zhľuky trénovacích a testovacích pixlov boli vybrané na základe porastových máp a s prihliadnutím na vytvorenú NDVI vrstvu a na google mapu, ktorá používa snímky s vysokým priestorovým rozlíšením z roku 2017.

Zo 6 snímok boli do klasifikácie vybrané len kanály B, G, R, NIR.

Osobitne nad každou snímkou musela byť vytvorená trénovacia a testovacia vzorka. Následne bola každá snímka klasifikovaná metódou Maximum Likelihood

Classifiacation. Ďalším krokom bolo orezať vyklasifikovanú vrstvu do tvaru referenčného územia.

6.12 Porovnávanie výsledkov

Následne klasifikované vrstvy boli prevedené z rastrovej vrstvy do vektorovej vrstvy. Atribútové tabuľky týchto vrstiev boli skopírované do Microsoft Excel. V Microsoft Excel bolo pomocou viacerých funkcií vypočítané to, ktoré pixle boli aspoň 4-krát zo 6 prípadov klasifikované do rovnakej triedy. Výsledkom tejto operácie v Microsoft Excel bol nový atribút, ktorý v prípade že konkrétny pixel bol klasifikovaný aspoň 4-krát do rovnakej triedy obsahoval hodnotu triedy (a to 1 až 5) a v prípade, že daný pixel nespĺňal požadovanú podmienku bola mu priradená hodnota nula.

V 3 prípadoch z 5 boli aspoň 4 hodnoty pixla zo 6 klasifikované do rovnakej triedy.

Časť tabuľky v softvéri Microsoft Excel s výsledným atribútom bola pripojená k atribútovej tabuľke v ArcGIS a na základe toho bola vyexportovaná nová vrstva.

6.13 Vytvorenie umelej trénovacej množiny pixlov

Pre vytvorenie umelej trénovacej množiny je potrebné vypočítať priemernú hodnotu umelých trénovacích a testovacích množín z pôvodných snímok pre každú snímku, triedu a kanál. To je $6 \times 5 \times 4$, takže spolu 120 priemerov hodnôt z pôvodných snímok.

Trénovaciú množinu pre jednu triedu musia tvoriť aspoň 2 pixle, ktoré však majú rovnakú hodnotu. Preto sa vytvorí nová vektorová vrstva, ktorá obsahuje 10 zvektorizovaných pixlov (2 pixle pre každú triedu). V tejto vrstve sa vytvorilo 10 záznamov (2 záznamy pre každú triedu) a 5 atribútov pre ID Triedy, B-band, G-band, R-band a NIR-band. Z Excelu sa prekopírovali priemerné hodnoty do tejto atribútovej tabuľky.

Pri vytváraní umelých trénovacích a testovacích množín bolo možné postupovať aj inak. Pri počítaní priemeru bolo možné nepočítať priemery zo všetkých hodnôt, ale vybrať len určité množstvo náhodných pixlov, čo by urýchlilo výpočet pri väčšom množstve dát. A navyše tento spôsob vytvorenia trénovacích množín by vytvoril možnosť spraviť aj umelé testovacie množiny.

Taktiež z Microsoft Excel je možné trénovacie množiny vyexportovať do ArcGISu ako tabuľku a pripojiť ju k už vytvorenej vektorovej vrstve obsahujúcej 10 zvektorizovaných pixlov.

Vytvorenú vektorovú vrstvu bolo možné použiť na vytvorenie .gsg vrstvy trénovacích množín, ktorá bola vytvorená pre priame použitie v klasifikačnom nástroji.

Po klasifikácii bol nový vyklasifikovaný obraz orezaný podľa hraníc referenčnej vrstvy, takže podľa hraníc lesa katastrov Osvätimany a Buchlovice.

6.14 Porovnanie výsledkov pomocou chybovej matice

Výsledky presnosti klasifikácií boli porovnávané pomocou chybových matic. Do chybových matic sa vložili dáta klasifikovanej vrstvy aj referenčnej vrstvy. Z chybovej matice bolo možné vypočítať celkovú presnosť klasifikácie.

Verzie ArcGISu 10.4.1 a 10.5.1 [15] majú sadu nástrojov na vypočítanie chybovej matice. Vo verzii 10.3.1 a v starších verziách je nutné použiť zdĺhavejší proces využitím väčšieho množstva rôznych nástrojov určených pre širokú škálu rôznych účelov.

Následne bolo možné na základe celkovej presnosti porovnávať správnosť vyklasifikovaných vrstiev.

Obr. č. 3: Príklad chybovej matice v ArcGISe

CCM_1_131001									
OID	ClassValue	C 1	C 2	C 3	C 4	C 5	Total	U Accuracy	Kappa
0	C 1	114	38	0	0	1	153	0,745098	0
1	C 2	53	132	8	6	11	210	0,628571	0
2	C 3	4	1	103	33	46	187	0,550802	0
3	C 4	4	23	62	80	21	190	0,421053	0
4	C 5	5	18	14	15	273	325	0,84	0
5	Total	180	212	187	134	352	1065	0	0
6	P Accuracy	0,633333	0,622642	0,550802	0,597015	0,775568	0	0,659155	0
7	Kappa	0	0	0	0	0	0	0	0,564319

Zdroj: autor

7 Diskusia

7.1 Porovnanie výsledkov z pohľadu druhov množín pixlov a klasifikačných tried

Snímky boli klasifikované podľa klasifikačnej metódy Maximum Likelihood s použitím kanálov B, G, R a NIR družice Landsat-8. V tejto podkapitole je opísané podľa ktorej skupiny množín pixlov dosiahla klasifikácia snímok najvyššiu a najnižšiu celkovú presnosť. Tiež je v tejto kapitole opísané, ktoré triedy dosiahli najlepšiu a ktoré najhoršiu užívateľskú a procesnú presnosť.

Snímky, ktoré boli klasifikované pomocou trénovacích množín, dosiahli celkovú presnosť klasifikácie od 0,482 do 0,683. Snímky klasifikované na základe testovacích množín dosiahli celkovú presnosť klasifikácie od 0,504 do 0,719. Klasifikácia na základe 6 snímok podľa trénovacích množín dosiahla celkovú presnosť 0,554. Snímky klasifikované pomocou umelých trénovacích množín dosiahli celkovú presnosť klasifikácie od 0,121 do 0,344.

Z pohľadu používateľskej presnosti u trénovacích a testovacích snímok najlepšie dopadla klasifikácia 1. triedy (Mladší dub) a to s hodnotami od 0,505 do 0,9. U klasifikácii na základe 6 snímok vyšla celková presnosť 1. triedy dokonca 0,962. Z pohľadu procesnej presnosti u trénovacích a testovacích snímok najlepšie dopadla klasifikácia 1. triedy a to s hodnotami od 0,505 do 0,844.

Z pohľadu používateľskej presnosti u trénovacích a testovacích množín najhoršie dopadla klasifikácia 4. triedy (Stredne-starší buk) s hodnotami od 0,622 do 0,536. Z pohľadu procesnej presnosti najhoršie dopadla klasifikácia pomocou trénovacích množín 3. trieda a pomocou testovacích množín 2. a 4. trieda (Starší buk a Stredne-starší buk).

Klasifikácia snímok pomocou testovacích množín dosiahla vyššiu celkovú presnosť, ako klasifikácia pomocou trénovacích množín. Dôvodom je asi nie úplne najvhodnejší výber trénovacích pixlov. Najvyššiu užívateľskú a procesnú presnosť dosiahla 1. trieda, dôvodom je pravdepodobne zvolenie vhodných trénovacích a testovacích množín pixlov. Najnižšiu užívateľskú a procesnú presnosť dosiahli 2., 3. a 4. trieda pomocou trénovacích a testovacích množín pixlov. Dôvodom je vybratie nie úplne najreprezentatívnych množín pixlov.

7.2 Porovnanie výsledkov v rámci snímok

V tejto podkapitole je zhodnotené, ktoré snímky dosiahli najlepšie a ktoré najhoršie výsledky.

Najvyššiu celkovú presnosť klasifikácie dosiahla s použitím trénovacích a aj testovacích množín snímka L8_150320 (t.j. z 20.3.2015) s hodnotami 0,683 a 0,719. Najvyššiu celkovú presnosť klasifikácie dosiahla s použitím umelých trénovacích množín snímka L8_140310 (t.j. z 10.3.2014) a to 0,344.

Najnižšiu celkovú presnosť klasifikácie dosiahla s použitím trénovacích množín snímka L8_160721 (t.j. z 21.7.2016) a to 0,482. Najnižšiu celkovú presnosť klasifikácie dosiahla s použitím testovacích a aj umelých trénovacích množín snímka L8_160930 (t.j. z 30.9.2016) s hodnotami 0,504 a 0,121.

Z chybových matíc (Prílohy 10.3, 10.7, 10.10) je vidieť, že najvyššiu celkovú presnosť dosiahli snímky z mesiaca marec, teda z jarneho ročného obdobia. Horšiu celkovú presnosť dosiahli klasifikované snímky z mesiacov júl, september a október. Snímky za jarne obdobie dosiahli najlepšiu klasifikáciu pravdepodobne preto, že dub a buk majú navzájom posunuté vegetačné obdobie o 7 až 10 dní, ako uvádza *Bucha a kol.* [2]

Tab. č. 1: Prehľad výsledkov celkovej presnosti klasifikácií snímok

	Trénovacie množiny pixlov	Testovacie množiny pixlov	Umelé trénovacie množiny pixlov
L8_131001	0,659	0,656	0,225
L8_140310	0,657	0,691	0,344
L8_150320	0,683	0,719	0,207
L8_150703	0,507	0,555	0,194
L8_160721	0,482	0,571	0,307
L8_160930	0,497	0,504	0,121

Zdroj: autor

7.3 Návrhy na zlepšenie výsledkov

Čo sa týka predspracovania snímok pred klasifikáciou, vyššia celková presnosť by mohla byť dosiahnutím, odstránením rozdielov v DN hodnotách medzi lesom na južnej a na severnej strane. Malo by sa to dať odstrániť pomocou jednoduchých aritmetických operácií.

V prácach *Carleer A.* a *E. Wolff* a [7] a *Immitzer a kol.* [9] uvádzajú, že snímky s vyššou priestorovou presnosťou prispievajú k vyššej celkovej presnosti klasifikácie. Na základe toho odporúčam použiť metódu prezentovanú v tejto práci na dáta družíc s vyšším priestorovým rozlíšením.

Ďalšou možnosťou ako zvýšiť celkovú presnosť klasifikácie je znížiť počet vstupných pixlov pre vznik umelých trénovacích množín zakomponovaním vrstvy o dôveryhodnosti vyklasifikovaných pixlov a vybrať len tie pixle, ktoré majú najvyššiu dôveryhodnosť. [15]

Ďalšou možnosťou je upraviť metódu, ktorá bola v práci použitá a to upraviť kritéria na základe, ktorých sa budú vyberať hodnoty pixlov do umelých trénovacích množín pixlov. Tiež je možné z DN hodnôt vybraných pixlov vypočítať DN hodnoty umelých trénovacích pixlov iným spôsobom, ako vypočítaním priemeru.

Články o umelých, alebo modifikovaných trénovacích množinách pixlov neboli nájdené medzi internetovými zdrojmi a preto sa vynára široká škála otázok o výskume v tejto oblasti.

Metódu v tejto práci je možné použiť aj na dáta zo satelitu Sentinel-2. Dôvody prečo neboli v tejto práci použité snímky z družice Sentinel-2 sú dva. Prvým je, že v čase vyberania vhodných snímok pre túto prácu neboli nájdené žiadne vhodné snímky z jarneho obdobia a preto snímky z družice Sentinel-2 neboli použité v tejto práci. Druhým dôvodom nebola voľná dostupnosť snímok s atmosferickou a rádiometrickou korekciou.

8 Záver

V posledných rokoch vďaka rýchlo rozvíjajúcim metódam DPZ, si vedia lesní pracovníci vytvoriť stále lepšiu predstavu o stave lesa, ktorý spravujú. Najdostupnejšie dáta získajú z multispektrálnych družíc Landsat-8 a Sentinel-2.

Najvhodnejšími metódami spracovania týchto snímok sú metódy pixelovej klasifikácie, kvôli priestorovému rozlíšeniu pixlov dát týchto družíc. Pomocou rešerše literatúry nachádzajúcej sa v tejto práci bola pre túto prácu vybraná klasifikačná metóda Maximum Likelihood. Z družicových dát boli vybrané kanály B, G, R a NIR kvôli nízkej korelácii kanálov.

Metóda použitá v tejto práci sa líši od klasifikačnej metódy Maximum Likelihood tým, že namiesto trénovacích množín pixlov, používa umelé trénovacie množiny pixlov, vypočítané ako priemery z vybraných pixlov družicových dát na základe opakovaného zaraďovania pixlov z rôznych snímok do tých istých tried pri klasifikácii použitím bežných trénovacích vzoriek pixlov.

V tejto práci boli skúmané spektrálne vlastnosti druhov drevín predovšetkým dubu a buku. Najlepšie je skúmať tieto druhy drevín pri použití kanálov B, G, R a NIR a klasifikačnej metódy Maximum Likelihood zo snímok získaných v jarnom období. V lete a na jeseň vyšla celková presnosť klasifikácie nižšia. Je to dané pravdepodobne tým, že na jar má dub od buka posunutú vegetačné obdobie o 7 až 10 dní.

Klasifikácie snímok pomocou umelých trénovacích množín dosiahli o niečo horšie výsledky, ako klasifikácie s použitím bežných trénovacích a testovacích množín. Návrhy ako dosiahnuť lepšie výsledky sú uvedené v diskusii práce.

9 Použité zdroje a literatúra

- [1] Feranec J. a kol., Meniace sa Slovensko očami satelitov, Bratislava: VEDA, Vydavateľstvo SAV, 2012.
- [2] Bucha T. a kol., Satelity v službách lesa, Zvolen: Národné lesnícke centrum, 2014.
- [3] „Lesná Pedagogika,“ NLC - ÚLPV Zvolen, 2009. [Online]. Available: <http://www.lesnapedagogika.sk/deti/zlozka.php?content=88>. [Cit. 15. 4. 2017].
- [4] Immitzer M. a kol., „Tree Species Classification with Random Forest Using Very High Spatial Resolution 8-Band WorldView-2 Satellite Data,“ *Remote Sensing*, zv. 4, %1. vyd.10.3390/rs4092661, pp. 2661-2693, 2012.
- [5] Verlič A. a kol., „Tree species classification using WorldView-2 satellite images and laser scanning data in a natural urban forest,“ *Šumarski list*, %1. vyd.9-10, pp. 477-488, 2014.
- [6] Lin C. a kol. , „Classification of Tree Species in Overstorey Canopy of Subtropical Forest Using QuickBird Images,“ *Plos One*, %1. vyd.10, 2015.
- [7] Carleer A. a Wolff E., „Exploitation of Very High Resolution Satellite Data for Tree Species Identification,“ *Photogrammetric Engineering and Remote Sensing*, %1. vyd.1, pp. 135 - 140, 2004.
- [8] Krahwinkler P. a Rossmann J., „Tree Species Classification Based on the Analysis of Hyperspectral Remote Sensing Data,“ *EARSel, Rainer Reuter (Editor)* , %1. vyd.1, pp. 321 - 327, 2010.
- [9] Immitzer M. a kol., „Suitability of Sentinel-2 Data for Tree Species Classification in Central Europe,“ rev. *LivingPlanet16*, Praha, 2016.
- [10] Bucha T., „Klasifikácia drevinového zloženia lesov Slovenska zo satelitných snímok ako súčasť monitorovania biodiverzity lesných ekosystémov,“ rev. *Lesnícky výskumný ústav*, Zvolen, 2007.
- [11] Huete A., „A Soil-Adjusted Vegetation Index (SAVI),“ *Remote Sensing of Environment*, zv. 25, %1. vyd.3, pp. 295 - 309, 1988.
- [12] Japan Association of Remote Sensing, 1996. [Online]. Available: <http://wtlab.iis.u-tokyo.ac.jp/~wataru/lecture/rsgis/rsnote/cp11/cp11-7.htm>. [Cit. 22 7 2017].
- [13] I. Environmental Systems Research Institute, „ArcGIS for Desktop,“ ESRI, 2016. [Online]. Available: <http://desktop.arcgis.com/en/arcmap/10.3/tools/spatial-analyst-toolbox/maximum-likelihood-classification.htm>. [Cit. 22 7 2017].

- [14] T. Hengl, „spatial-analyst.net,“ 2016. [Online]. Available: http://spatial-analyst.net/ILWIS/htm/ilwismen/confusion_matrix.htm. [Cit. 22 7 2017].
- [15] I. Environmental Systems Research Institute, „ArcGIS for Desktop,“ ESRI, 2016. [Online]. Available: <http://desktop.arcgis.com/en/arcmap/10.3/tools/spatial-analyst-toolbox/maximum-likelihood-classification.htm>. [Cit. 22 7 2017].
- [16] „How to convert Landsat DN's to Top of Atmosphere (ToA) Reflectance,“ Center for Earth Observation, Yale University, 2017. [Online]. Available: <http://yceo.yale.edu/how-convert-landsat-dns-top-atmosphere-toa-reflectance>. [Cit. 18. 4. 2017].
- [17] „Using the USGS Landsat 8 Product,“ U.S. Geological Survey, 29. 11. 2016. [Online]. Available: <https://landsat.usgs.gov/using-usgs-landsat-8-product>. [Cit. 18. 4. 2017].
- [18] Viňa A. a kol., „Monitoring Maize (*Zea mays* L.) Phenology with Remote Sensing,“ *Papers in Natural Resources*, %1. vyd.7, pp. 1137 - 1147, 2004.
- [19] Lindsay I. Smith, „A tutorial on Principal Components Analysis,“ Cornell University, USA, 2002. [Online]. Available: http://www.cs.otago.ac.nz/cosc453/student_tutorials/principal_components.pdf. [Cit. 18. 4. 2017].
- [20] Jolliffe I.T., *Principal Component Analysis*, Second Edition, New York, USA: Springer-Verlag New York, Inc., 2002.
- [21] Sarvaš M. a kol., *Základné charakteristiky lesných drevín*, Zvolen: Národné lesnícke centrum, 2010.

Použité zdroje dát:

[a] Portál LandsatLook Viewer (U.S. Geological Survey)

<http://landsatlook.usgs.gov/>

[b] Portál Sentinel-2 Pre-Operations Data Hub (ESA)

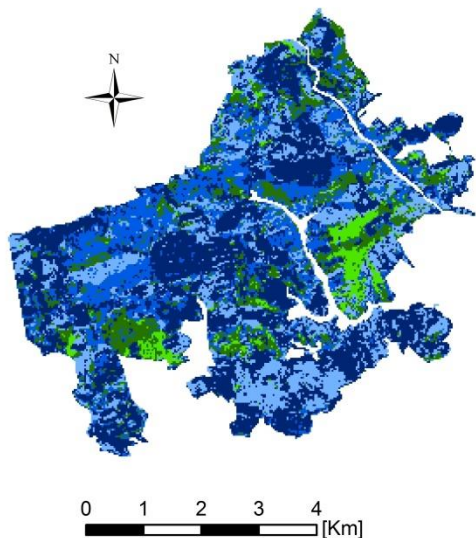
<https://scihub.copernicus.eu/s2/#/home>

10 Prílohy

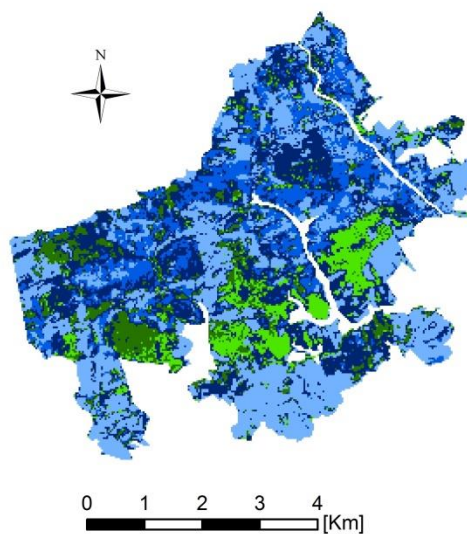
10.1 Klasifikácia lesov podľa trénovacích množín k.ú. Osvětman a Buchlovíc

Klasifikácia lesov podľa trénovacích množín k.ú. Osvětman a Buchlovíc


Vyklasifikovaná snímka L-8
1.10.2013



Vyklasifikovaná snímka L-8
10.3.2014



Vyklasifikovaná snímka L-8
20.3.2015




Klasifikačné triedy:

-  1 - mladší dub
-  2 - starší dub
-  3 - mladší buk
-  4 - strednestarší buk
-  5 - starší buk


10.2 Klasifikácia lesov podľa trénovacích množín k.ú. Osvětman a Buchlovíc (2)

Klasifikácia lesov podľa trénovacích množín k.ú. Osvětman a Buchlovíc (2)


Vyklasifikovaná snímka L-8
3.7.2015



Vyklasifikovaná snímky L-8
21.7.2016



Vyklasifikovaná snímky L-8
30.9.2016



Klasifikačné triedy:

-  1 - mladší dub
-  2 - starší dub
-  3 - mladší buk
-  4 - strednestarší buk
-  5 - starší buk

10.3 Chybové matice klasifikácie lesov podľa tréningových množín k.ú. Osvětman a Buchlovíc

CCM_1_131001

OID	ClassValue	C 1	C 2	C 3	C 4	C 5	Total	U Accuracy	Kappa
0	C 1	114	38	0	0	1	153	0,745098	0
1	C 2	53	132	8	6	11	210	0,628571	0
2	C 3	4	1	103	33	46	187	0,550802	0
3	C 4	4	23	62	80	21	190	0,421053	0
4	C 5	5	18	14	15	273	325	0,84	0
5	Total	180	212	187	134	352	1065	0	0
6	P Accuracy	0,633333	0,622642	0,550802	0,597015	0,775568	0	0,659155	0
7	Kappa	0	0	0	0	0	0	0	0,564319

CCM_1_140310

OID	ClassValue	C 1	C 2	C 3	C 4	C 5	Total	U Accuracy	Kappa
0	C 1	143	31	0	0	6	180	0,794444	0
1	C 2	19	155	2	4	16	196	0,790816	0
2	C 3	0	0	66	8	27	101	0,653465	0
3	C 4	0	1	90	59	26	176	0,335227	0
4	C 5	18	25	29	63	277	412	0,67233	0
5	Total	180	212	187	134	352	1065	0	0
6	P Accuracy	0,794444	0,731132	0,352941	0,440299	0,786932	0	0,657277	0
7	Kappa	0	0	0	0	0	0	0	0,554612

CCM_1_150320

OID	ClassValue	C 1	C 2	C 3	C 4	C 5	Total	U Accuracy	Kappa
0	C 1	138	18	0	0	3	159	0,867925	0
1	C 2	35	183	1	2	18	239	0,76569	0
2	C 3	1	0	64	14	32	111	0,576577	0
3	C 4	0	3	85	75	31	194	0,386598	0
4	C 5	6	8	37	43	268	362	0,740331	0
5	Total	180	212	187	134	352	1065	0	0
6	P Accuracy	0,766667	0,863208	0,342246	0,559701	0,761364	0	0,683568	0
7	Kappa	0	0	0	0	0	0	0	0,592505

CCM_1_150703

OID	ClassValue	C 1	C 2	C 3	C 4	C 5	Total	U Accuracy	Kappa
0	C 1	91	15	33	9	32	180	0,505556	0
1	C 2	45	133	24	27	65	294	0,452381	0
2	C 3	8	6	48	15	50	127	0,377953	0
3	C 4	9	38	69	78	15	209	0,373206	0
4	C 5	27	20	13	5	190	255	0,745098	0
5	Total	180	212	187	134	352	1065	0	0
6	P Accuracy	0,505556	0,627358	0,256684	0,58209	0,539773	0	0,507042	0
7	Kappa	0	0	0	0	0	0	0	0,377354

CCM_1_160930

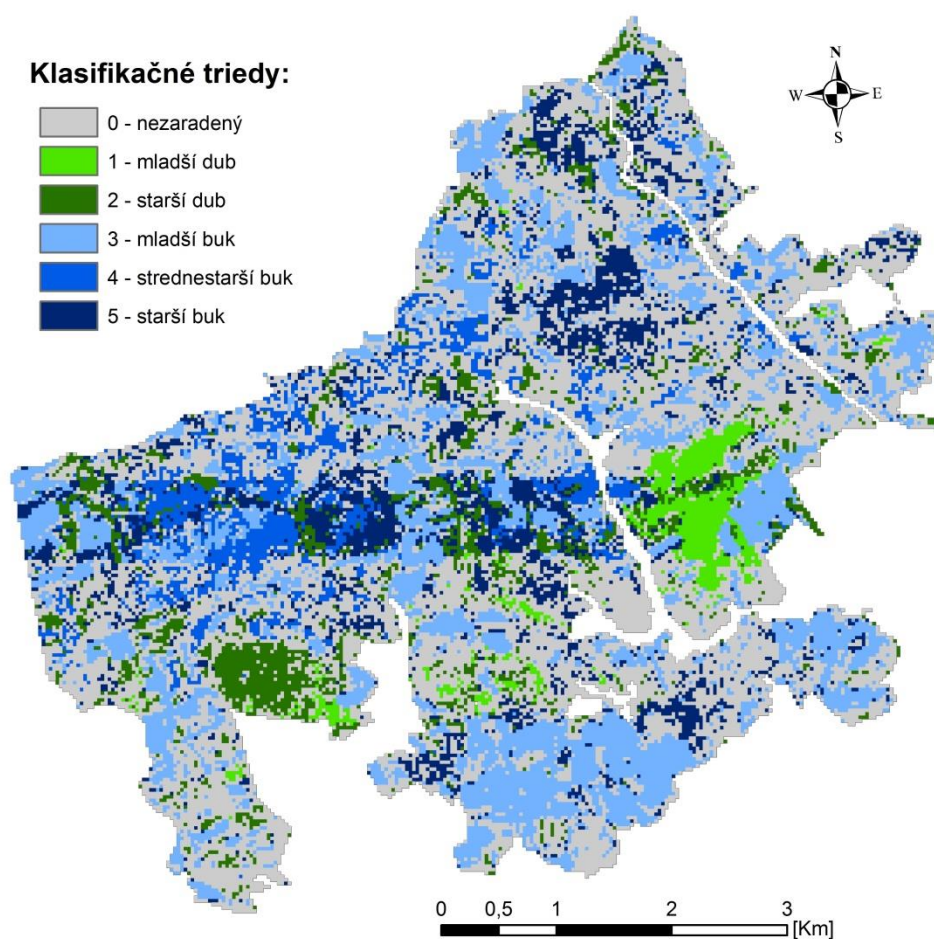
OID	ClassValue	C 1	C 2	C 3	C 4	C 5	Total	U Accuracy	Kappa
0	C 1	135	10	1	0	4	150	0,9	0
1	C 2	36	113	10	20	86	265	0,426415	0
2	C 3	4	15	108	33	99	259	0,416988	0
3	C 4	1	43	41	67	56	208	0,322115	0
4	C 5	4	31	27	14	107	183	0,584699	0
5	Total	180	212	187	134	352	1065	0	0
6	P Accuracy	0,75	0,533019	0,57754	0,5	0,303977	0	0,497653	0
7	Kappa	0	0	0	0	0	0	0	0,374096

CCM_1_160721

OID	ClassValue	C 1	C 2	C 3	C 4	C 5	Total	U Accuracy	Kappa
0	C 1	132	15	0	0	3	150	0,88	0
1	C 2	27	99	18	11	43	198	0,5	0
2	C 3	4	23	44	14	105	190	0,231579	0
3	C 4	1	50	37	95	57	240	0,395833	0
4	C 5	16	25	88	14	144	287	0,501742	0
5	Total	180	212	187	134	352	1065	0	0
6	P Accuracy	0,733333	0,466981	0,235294	0,708955	0,409091	0	0,482629	0
7	Kappa	0	0	0	0	0	0	0	0,345463

10.4 Klasifikácia lesov na základe 6 snímkov podľa trénovacích množín k.ú. Osvětman a Buchlovíc

Klasifikácia lesov na základe 6 snímkov podľa trénovacích množín k.ú. Osvětman a Buchlovíc




CCM_F2a										
OID	ClassValue	C 0	C 1	C 2	C 3	C 4	C 5	Total	U Accuracy	Kappa
0 C 0	0	0	27	65	75	30	139	336	0	0
1 C 1	0	0	129	5	0	0	0	134	0,962687	0
2 C 2	0	0	24	140	0	2	8	174	0,804598	0
3 C 3	0	0	0	0	61	19	15	95	0,642105	0
4 C 4	0	0	0	1	45	74	3	123	0,601626	0
5 C 5	0	0	0	1	6	9	187	203	0,921182	0
6 Total	0	0	180	212	187	134	352	1065	0	0
7 P Accuracy	0	0,716667	0,660377	0,326203	0,552239	0,53125	0	0	0,55493	0
8 Kappa	0	0	0	0	0	0	0	0	0	0,47824


10.5 Klasifikácia lesov podľa umelých trénovacích množín k.ú. Osvětman a Buchlovíc

Klasifikácia lesov podľa umelých trénovacích množín k.ú. Osvětman a Buchlovíc


Vyklasifikovaná snímka L-8
1.10.2013



Vyklasifikovaná snímka L-8
10.3.2014



Vyklasifikovaná snímka L-8
20.3.2015




Klasifikačné triedy:

- 1 - mladší dub
- 2 - starší dub
- 3 - mladší buk
- 4 - strednestarší buk
- 5 - starší buk


10.6 Klasifikácia lesov podľa umelých trénovacích množín k.ú. Osvětman a Buchlovíc (2)

Klasifikácia lesov podľa umelých trénovacích množín k.ú. Osvětman a Buchlovíc (2)


Vyklasifikovaná snímka L-8
3.7.2015



Vyklasifikovaná snímky L-8
21.7.2016



Vyklasifikovaná snímky L-8
30.9.2016



Klasifikačné triedy:

- 1 - mladší dub
- 2 - starší dub
- 3 - mladší buk
- 4 - strednestarší buk
- 5 - starší buk

10.7 Chybové matice klasifikácie lesov podľa umelých trénovacích množín k.ú. Osvětman a Buchlovíc

CCM_3_131001

OID	ClassValue	C 1	C 2	C 3	C 4	C 5	Total	U Accuracy	Kappa
0	C 1	169	163	153	77	304	866	0,19515	0
1	C 2	7	48	32	54	23	164	0,292683	0
2	C 3	0	0	0	0	0	0	0	0
3	C 4	0	0	0	0	2	2	0	0
4	C 5	4	1	2	3	23	33	0,69697	0
5	Total	180	212	187	134	352	1065	0	0
6	P Accuracy	0,938889	0,226415	0	0	0,065341	0	0,225352	0
7	Kappa	0	0	0	0	0	0	0	0,056959

CCM_3_140310

OID	ClassValue	C 1	C 2	C 3	C 4	C 5	Total	U Accuracy	Kappa
0	C 1	43	44	2	4	37	130	0,330769	0
1	C 2	84	122	0	23	65	294	0,414966	0
2	C 3	2	0	128	41	193	364	0,351648	0
3	C 4	1	2	5	38	21	67	0,567164	0
4	C 5	50	44	52	28	36	210	0,171429	0
5	Total	180	212	187	134	352	1065	0	0
6	P Accuracy	0,238889	0,575472	0,684492	0,283582	0,102273	0	0,344601	0
7	Kappa	0	0	0	0	0	0	0	0,171761

CCM_3_150320

OID	ClassValue	C 1	C 2	C 3	C 4	C 5	Total	U Accuracy	Kappa
0	C 1	3	8	14	29	27	81	0,037037	0
1	C 2	142	183	173	70	245	813	0,225092	0
2	C 3	0	0	0	0	0	0	0	0
3	C 4	35	21	0	35	80	171	0,204678	0
4	C 5	0	0	0	0	0	0	0	0
5	Total	180	212	187	134	352	1065	0	0
6	P Accuracy	0,016667	0,863208	0	0,261194	0	0	0,207512	0
7	Kappa	0	0	0	0	0	0	0	0,027602

CCM_3_150703

OID	ClassValue	C 1	C 2	C 3	C 4	C 5	Total	U Accuracy	Kappa
0	C 1	168	178	164	105	338	953	0,176285	0
1	C 2	12	34	18	20	14	98	0,346939	0
2	C 3	0	0	5	9	0	14	0,357143	0
3	C 4	0	0	0	0	0	0	0	0
4	C 5	0	0	0	0	0	0	0	0
5	Total	180	212	187	134	352	1065	0	0
6	P Accuracy	0,933333	0,160377	0,026738	0	0	0	0,194366	0
7	Kappa	0	0	0	0	0	0	0	0,02717

CCM_3_160721

OID	ClassValue	C 1	C 2	C 3	C 4	C 5	Total	U Accuracy	Kappa
0	C 1	80	59	13	28	42	222	0,36036	0
1	C 2	15	19	0	4	17	55	0,345455	0
2	C 3	5	0	14	2	59	80	0,175	0
3	C 4	67	55	42	42	62	268	0,156716	0
4	C 5	13	79	118	58	172	440	0,390909	0
5	Total	180	212	187	134	352	1065	0	0
6	P Accuracy	0,444444	0,089623	0,074866	0,313433	0,488636	0	0,307042	0
7	Kappa	0	0	0	0	0	0	0	0,103647

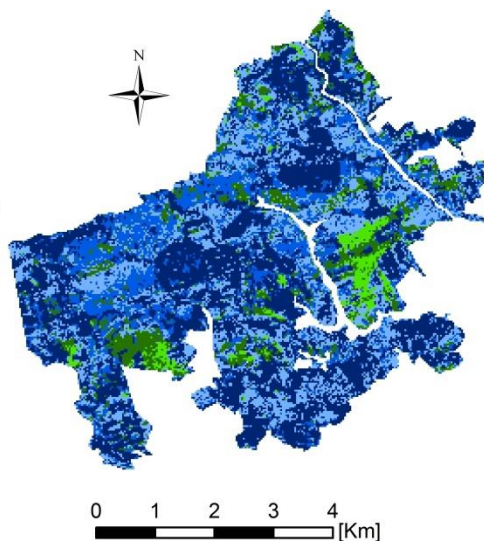
CCM_3_160930

OID	ClassValue	C 1	C 2	C 3	C 4	C 5	Total	U Accuracy	Kappa
0	C 1	85	153	18	77	118	451	0,18847	0
1	C 2	10	44	169	56	225	504	0,087302	0
2	C 3	85	15	0	1	9	110	0	0
3	C 4	0	0	0	0	0	0	0	0
4	C 5	0	0	0	0	0	0	0	0
5	Total	180	212	187	134	352	1065	0	0
6	P Accuracy	0,472222	0,207547	0	0	0	0	0,121127	0
7	Kappa	0	0	0	0	0	0	0	-0,076935


10.8 Klasifikácia lesov podľa testovacích množín k.ú. Osvětiman a Buchlovíc

Klasifikácia lesov podľa testovacích množín k.ú. Osvětiman a Buchlovíc


Vyklasifikovaná snímka L-8
1.10.2013



Vyklasifikovaná snímka L-8
10.3.2014



Vyklasifikovaná snímka L-8
20.3.2015




Klasifikačné triedy:

-  1 - mladší dub
-  2 - starší dub
-  3 - mladší buk
-  4 - strednestarší buk
-  5 - starší buk


10.9 Klasifikácia lesov podľa testovacích množín k.ú. Osvětiman a Buchlovíc (2)

Klasifikácia lesov podľa testovacích množín k.ú. Osvětiman a Buchlovíc (2)


Vyklasifikovaná snímka L-8
3.7.2015



Vyklasifikovaná snímky L-8
21.7.2016



Vyklasifikovaná snímky L-8
30.9.2016



Klasifikačné triedy:

- 1 - mladší dub
- 2 - starší dub
- 3 - mladší buk
- 4 - strednestarší buk
- 5 - starší buk

10.10 Chybové matice klasifikácie lesov podľa testovacích množín k.ú. Osvětman a Buchlovíc

CCM_2_131001

OID	ClassValue	C 1	C 2	C 3	C 4	C 5	Total	U Accuracy	Kappa
0	C 1	98	37	1	0	0	136	0,720588	0
1	C 2	57	115	2	6	4	184	0,625	0
2	C 3	10	17	122	40	44	233	0,523605	0
3	C 4	5	17	36	75	15	148	0,506757	0
4	C 5	10	26	26	13	289	364	0,793956	0
5	Total	180	212	187	134	352	1065	0	0
6	P Accuracy	0,544444	0,542453	0,652406	0,559701	0,821023	0	0,656338	0
7	Kappa	0	0	0	0	0	0	0	0,556657

CCM_2_140310

OID	ClassValue	C 1	C 2	C 3	C 4	C 5	Total	U Accuracy	Kappa
0	C 1	152	23	0	3	30	208	0,730769	0
1	C 2	16	169	2	3	17	207	0,816425	0
2	C 3	0	0	121	20	45	186	0,650538	0
3	C 4	1	1	48	64	30	144	0,444444	0
4	C 5	11	19	16	44	230	320	0,71875	0
5	Total	180	212	187	134	352	1065	0	0
6	P Accuracy	0,844444	0,79717	0,647059	0,477612	0,653409	0	0,69108	0
7	Kappa	0	0	0	0	0	0	0	0,604613

CCM_2_150320

OID	ClassValue	C 1	C 2	C 3	C 4	C 5	Total	U Accuracy	Kappa
0	C 1	131	17	1	0	3	152	0,861842	0
1	C 2	39	185	0	2	11	237	0,780591	0
2	C 3	0	1	127	34	65	227	0,559471	0
3	C 4	0	3	38	67	17	125	0,536	0
4	C 5	10	6	21	31	256	324	0,790123	0
5	Total	180	212	187	134	352	1065	0	0
6	P Accuracy	0,727778	0,872642	0,679144	0,5	0,727273	0	0,719249	0
7	Kappa	0	0	0	0	0	0	0	0,639524

CCM_2_150703

OID	ClassValue	C 1	C 2	C 3	C 4	C 5	Total	U Accuracy	Kappa
0	C 1	94	21	27	8	17	167	0,562874	0
1	C 2	25	91	30	15	11	172	0,52907	0
2	C 3	19	22	61	27	27	156	0,391026	0
3	C 4	11	42	45	71	22	191	0,371728	0
4	C 5	31	36	24	13	275	379	0,725594	0
5	Total	180	212	187	134	352	1065	0	0
6	P Accuracy	0,522222	0,429245	0,326203	0,529851	0,78125	0	0,555869	0
7	Kappa	0	0	0	0	0	0	0	0,427255

CCM_2_160721

OID	ClassValue	C 1	C 2	C 3	C 4	C 5	Total	U Accuracy	Kappa
0	C 1	111	10	2	0	3	126	0,880952	0
1	C 2	50	124	9	9	42	234	0,529915	0
2	C 3	3	30	107	23	95	258	0,414729	0
3	C 4	0	31	24	97	42	194	0,5	0
4	C 5	16	17	45	5	170	253	0,671937	0
5	Total	180	212	187	134	352	1065	0	0
6	P Accuracy	0,616667	0,584906	0,572193	0,723881	0,482955	0	0,571831	0
7	Kappa	0	0	0	0	0	0	0	0,459583

CCM_2_160930

OID	ClassValue	C 1	C 2	C 3	C 4	C 5	Total	U Accuracy	Kappa
0	C 1	144	13	0	0	5	162	0,888889	0
1	C 2	21	111	7	37	63	239	0,464435	0
2	C 3	3	21	124	33	63	244	0,508197	0
3	C 4	5	21	32	50	113	221	0,226244	0
4	C 5	7	46	24	14	108	199	0,542714	0
5	Total	180	212	187	134	352	1065	0	0
6	P Accuracy	0,8	0,523585	0,663102	0,373134	0,306818	0	0,504225	0
7	Kappa	0	0	0	0	0	0	0	0,381459